

LATVIJAS UNIVERSITĀTE
BIOLOĢIJAS FAKULTĀTE
ZOOLOĢIJAS UN DZĪVNIEKU EKOLOĢIJAS KATEDRA

SAVVAĻAS PĀRNADŽU POPULĀCIJAS
NOVĒRTĒŠANA, IZMANTOJOT VIZUĀLO
ATPAZĪŠANU MEŽA KAMERU DATOS, UN
SALĪDZINĀŠANA AR APMĀCĪTAS
MAŠĪNMĀCĪŠANĀS MODEĻA REZULTĀTU.

Maģistra darbs

Autors: Alekss Vecvanags

Stud. apl. Nr. av16090

Darba vadītājs: Dr. biol., Asoc. prof. Ainārs Auniņš

RĪGA 2022

KOPSAVILKUMS

Eiropā pēdējās desmitgadēs strauji palielinās pārnadžu populācijas, kas ik gadu rada simtiem miljonus eiro zaudējumus, tāpēc ir nepieciešamas metodes, lai efektīvi novērtētu pārnadžu populācijas. Meža kameras var būt labs risinājums, lai aizstātu uz vizuālajiem novērojumiem balstītas uzskaites bet tās ievāc lielus datu apjomus, kuru analīze aizņem ilgu laiku. To var risināt dziļās mašīnmācīšanās modeļi.

No 2021. gada 1.janvāra teritorijā pie Rāmuļiem visu gadu tika izliktas 22 meža kameras, ar kurām tika noteikts pārnadžu relatīvais daudzuma indekss. Staltbrieži sastādīja 83,2%, stirnas 8,2%, aļņi 3,8% un meža cūkas 4,6%. Tika uztrenēts YOLOv5 mašīnmācīšanās modelis, kurš spēja atpazīt pārnadžus ar 83,9% pareizību. Tas pareizi klasificēja 98,2% no detektētajām stirnām, 70,9% no detektētajām meža cūkām, bet staltbrieža klasifikācijas pareizība bija tikai 0,1%, un alnis netika pareizi klasificēts vispār. YOLOv5 modeļa detektētais dzīvnieku skaits spēja izskaidrot 51,1% no vizuālās novērošanas iegūtā dzīvnieku skaita.

Atslēgvārdi: Pārnadži, meža kameras, dziļā mašīnmācīšanās, relatīvais daudzuma indekss

SUMMARY

Ungulate populations are quickly increasing in Europe, which leads to hundreds of millions euro in losses, creating a need for effective methods to estimate ungulate populations. Camera traps can be a good solution to replace methods based on visual observations, but they acquire large amounts of data that take long to analyze. This can be solved with deep machine learning models.

22 camera traps were deployed near Rāmuși from January 1st 2021, from which relative population indices were derived. Red deer constituted 83,2% of all animals, roe deer 8,2%, elk 3,8%, and wild boar 4,6%. A YOLOv5 model was trained that achieved a detection accuracy of 83,9%. It correctly classified 98,2% of detected roe deer and 70,9% of wild boar, but red deer had a 0,1% classification accuracy and elk was not correctly classified at all. Counts of YOLOv5 model could explain 51,1% of counts from visual observations.

Keywords: Ungulates, camera traps, deep machine learning, relative abundance index

SATURS

1.	IEVADS	5
1	Literatūras apskats	7
1.1	Latvijā sastopamie savvaļas pārnadži	7
1.1.1	Staltbrieži (<i>Cervus elaphus</i>)	7
1.1.2	Stirnas (<i>Capreolus capreolus</i>)	8
1.1.3	Aļņi (<i>Alces alces</i>)	10
1.1.4	Meža cūkas (<i>Sus scrofa</i>)	11
1.2	Pārnadžu nozīme un ietekme uz ekosistēmām	13
1.3	Pārnadžu populāciju izpētes metodes	14
1.3.1	Tradicionālās metodes	15
1.3.2	Attālinātās metodes	17
1.4	Meža kameras	18
1.5	Mašīnmācīšanās modeļi	22
1.5.1	Dziļā mašīnmācīšanās	23
1.6	Mašīnmācīšanās modeļu pielietojums pārnadžu pētīšanā ar meža kamerām	24
2	Materiāls un metodes	26
2.1	Pētījuma vietas raksturojums	26
2.2	Datu ievākšanas metodes	26
2.3	Datu apstrādes metodes	28
2.4	Statistikas metodes	29
3	Rezultāti	31
4	Diskusija	53
5	Secinājumi	56
6	Pateicības	57
7	Izmantotā literatūra	58

1. IEVADS

Veselīgas pārnadžu populācijas spēlē nozīmīgu lomu daudzveidīgas ekosistēmas uzturēšanā, un var sniegt ekonomiskus ieguvumus caur medībām vai eko-tūrismu (Valente et al., 2020), bet pārnadžiem sasniedzot pārāk lielas populācijas, tie var negatīvi ietekmēt cilvēkus un apkārtējo vidi, radot zaudējumus lauksaimniecības un mežsaimniecības industrijās, bojājot aizsargājamas teritorijas, veidojot ceļu satiksmes negadījumus, un pārnēsājot slimības (Kušta et al., 2017; Putman et al., 2011a; Ruiz-Fons et al., 2014; Valente et al., 2020). Urbanizācijas, ziemas piebarošanas, reintrodukcijas, plēsēju samazināšanās, globālās sasilšanas u.c. iemeslu dēļ pārnadžu populācijas Eiropā un Latvijā pēdējās desmitgadēs strauji pieaug (Apollonio et al., 2014; Putman et al., 2011a; Putman et al., 2011b). Pārnadžu negatīvā ietekme lauksaimniecības, mežsaimniecības un ceļu satiksmes negadījumu rezultātā Eiropā izmaksā vairāk nekā vienu miljardu eiro gadā. Cūku mēris Nīderlandē ir nodarījis 1.8 miljardu eiro zaudējumu, un joprojām ir atrodams arī Latvijas meža cūku populācijās (Valente et al., 2020). Šo iemeslu dēļ, ir nepieciešams attīstīt viegli pielietojamas metodes pārnadžu populāciju novērtēšanai lielos mērogos. Tradicionālām metodēm, kā ekskrementu vai pēdu uzskaitēm, dzinēju uzskaitēm ir nepieciešami labi apmācīti eksperti un/vai liels cilvēku daudzums, kā arī tās spēj noteikt dzīvniekus tikai noteiktā laika brīdī (Burton et al., 2015; Taylor et al., 2022).

Šo iemeslu dēļ, meža kameras ir kļuvušas par plaši pielietotu tehnoloģiju pārnadžu populāciju novērtēšanā (Gilbert et al., 2020). Tās ir viegli uzstādāmas, izturīgas, neinvazīvas un salīdzinoši lētas, kā arī ļauj rezultātus apstrādāt jebkurā brīdī pēc eksperimenta (Burton et al., 2015). Liels šķērslis to pielietojumā ir lielais datu apjoms, ko tās ievāc, kuru analīze var aizņemt daudz laiku. To var risināt dziļās mašīnmācīšanās tehnoloģijas, kuras spēj attēlos automātiski atpazīt un klasificēt dzīvniekus (Norouzzadeh et al., 2018).

Darba izvirzītie mērķi ir:

1. Noteikt relatīvo populācijas lielumu pētījuma teritorijā četrām pārnadžu sugām - staltbriedim *Cervus elaphus*; mežacūkai *Sus scrofa*; stirnai *Capreolus capreolus*; alnim *Alces alces*, izmantojot meža kameras.
2. Novērtēt automātiskas mašīnmācīšanās izmantošanas iespējas populācijas lielumu noteikšanā un novērtēt tās precizitāti.

Un izvirzītie uzdevumi to sasniegšanai:

1. Novērtēt relatīvos populāciju lielumus.

2. Novērtēt kameru telpiskā izvietojuma un temporālo ietekmi uz pārnadžu populācijām.
3. Apmācīt mašīnmācīšanās modeli pārnadžu automātiskai detektēšanai un klasifikācijai.
4. Salīdzināt eksperta veiktas dzīvnieku vizuālas atpazīšanas attēlos metodes rezultātus ar mašīnmācīšanās modeļa rezultātiem relatīvās populācijas lieluma noteikšanā.

1 Literatūras apskats

1.1 Latvijā sastopamie savvaļas pārnadži

Latvijā ir sastopamas četras savvaļas pārnadžu *Artiodactyla* sugas, trīs no briežu dzimtas *Cervidae* - staltbriedis *Cervus elaphus*, stirna *Capreolus capreolus*, alnis *Alces alces* un viena no cūku dzimtas *Suidae* - meža cūka *Sus scrofa* (Meek et al., 2019). Visas šīs sugas ir plaši izplatītas un bieži sastopamas visā Latvijas teritorijā. Īpatņu skaits pēc Valsts Meža Dienesta (VMD) datiem 2021./2022. gada medību sezonā ir – 71 000 staltbrieži, 201 000 stirnas, 23 000 aļņi un 26 000 mežacūkas (VMD, 2017).

1.1.1 Staltbrieži (*Cervus elaphus*)

Staltbriedis Latvijas teritorijā ir ieceļojis agrā holocēna beigās, aptuveni pirms 8 tūkstošiem gadu, un to fosilās atliekas atrastas 15 senlatviešu nometnēs. Pēc tam staltbriežu skaits ir samazinājies līdz 2.gs. mūsu ērā, kad tie no Latvijas teritorijas izzuda pavisam. Suga Latvijā tika atkārtoti ieviesta sākot no 16. gs. briežu dārzos, no kuriem īpatņi nokļuva savvaļā un veidoja jaunas, stabilas populācijas (Skriba, 2011). Oficiāla staltbriežu reaklimatizācija savvaļā tika veikta pēc Kurzemes muižnieku 1902. gada 10. jūnija sapulces, kuri ik gadu veltīja 500 rubļus savvaļas populāciju uzturēšanai un kopšanai. Lielākas staltbriežu savvaļas populācijas Latvijas rietumu daļā veidojās tikai 50-60 gadus vēlāk. Kopš šī laika Latvijas teritorijā ir bijis pastāvīgs staltbriežu populācijas pieaugums (Skriba, 2011).

Staltbriedis ir otrs lielākais savvaļas dzīvnieks Latvijā, to tēviņi sver līdz 240 kg un sasniedz līdz 230 cm garumu, mātītes var sasniegt 170 kg svaru un 210 cm garumu (Spura, 1974). Vasaras sezonā staltbrieža apmatojums ir sarkanbrūns, bet rudens un ziemas sezonā kažoks paliek gaišāks ar pelēcīgāku nokrāsu, un biezāks. Tēviņiem rudens periodā uz skausta ir raksturīgas krēpes, un kopumā kakls ir masīvāks kā mātītēm. Īpatņi dzīvo no 16 līdz 18 gadiem, dzimumgatavība tēviņiem iestājas 2 gados vai 3 gados. Staltbriežu riests notiek no septembra līdz oktobrim, pēc kura mātīte maijā vai jūnijā dzemdē 1 vai 2 mazuļus (Tauriņš, 1982). Latvijā to galvenie dabīgie ienaidnieki ir vilki, lūši un lāči, un to mazuļus var medīt arī lapsas. (Macdonald, 2001)

Staltbriedis ir tipisks meža dzīvnieks, bet ir ekoloģiski plastisks un eiribionts. Staltbrieži izvairās no mežaudzēm ar biezu egles, bērza, alkšņa pamežiem, bet dod priekšroku vecākām un skrajākām audzēm ar bagātīgu pamežu, bet bieži sastopams arī pļavās un lauksaimniecības zemēs. Vasarā indivīda teritorija var sasniegt 300 ha, ziemā 100 ha (Tauriņš, 1982).

Pēc VMD uzskaitēm, Latvijā no 1995. līdz 1998. gadam īpatņu skaits samazinājās, no 24 902 līdz 20 026 īpatņiem (-19,58%), bet kopš 1998. gadam līdz 2021. gadam ir bijis konstants pieaugums un īpatņu skaits ir palielinājies par trīs ar pus reizēm, no 20 026 līdz 71 000 īpatņiem (+256,54%). Staltbriedis ir izplatīts visā Latvijā, ar visaugstāko populācijas blīvumu Kurzemē un Zemgales rietumu daļā (2021. gadā).

1.1.2 Stirnas (*Capreolus capreolus*)

Stirnas ir pielāgojušās dzīvei rietumpaeartikas platlapju mežu vai meža stepju biotopiem, un arī mērenās joslas boreālajos mežos. Latvijas teritorijā ieeļojušas subboreālā klimata periodā, agrā holocēnā. Skeleta atliekas atrastas vairākos vidēja un vēlā akmens laikmeta apmetnēs, visvairāk Latvijas dienvidos. Izplatīta visā teritorijā līdz vismaz 17. gs., bet Kurzemē sastopama līdz 17. un 18. gs. Areāla un skaita samazināšanās skaidrojama ar klimata izmaiņām, bargām ziemām, un vilku populācijas pieaugumu. Areāla palielināšanās sākās 19. gs. beigās ar klimata pasiltināšanos un vilka populācijas samazināšanos. 20. gs. sākumā stirnu izplatības areāla ziemeļu robeža sasniedza somu līci, un 1930. gados bija vērojams straujš populācijas pieaugums. Populācijas skaitu spēcīgi ir ietekmējušas bargas ziemas (Tauriņš, 1982).

Latvijā mazākā briežu dzimtas suga. Stirnas ir 100 līdz 130 cm garas, un sver no 20 līdz 40 kg. Tēviņi ir nedaudz lielāki par mātītēm. Stirnu ķermenis pret to izmēru ir salīdzinoši slaidis, garas kājas, maza galva ar lielām ausīm un acīm. Pieaugušiem īpatņiem ķermeņa apmatojums ir vienkrāsains un rupjš, vasarā rūsgans vai rūsgani sarkans un sastāv no akotmatiem. Ziemā tas ir rudi pelēks vai brūngani pelēks un sastāv no akotmatiem un pavilnas. Vēdera puse un astes daļa ir gaiša. Mazuļi līdz 4 mēnešu vecumam ir plankumaini. (Spura, 1974)

Suga ir raksturojama kā plastiska, un apdzīvo galvenokārt mežus un pusatvērtas ainavas. Apmetnes visbiežāk atrodas mazos mežos vai birztaļās, kas robežojas ar lauksaimniecības zemēm. Kā guļvietas visbiežāk izvēlas vietas ar biezu pamežu, bet ir atrodamas arī aizaugušos izcirtumos un skrajākās jaunaudzēs. Vasarā ganās laucēs, pļavās, izcirtumos, lauksaimniecību teritoriju nomalēs. Rudenī/ziemā pārvietojas uz meža teritorijām ar sīkrūmu segu, kur var uztverties visu ziemu. Sniega segai pārsniedzot 30 cm, stirnas pārvietojas uz meža nogabaliem ar lielu lapu koku un krūmu pamežu. Pavasaros tās galvenokārt atrodas ziemāju tīrumu apkārtnē. Teritorija vismazākais ir ziemā, kad tas var samazināties no 0,5 līdz 2 ha, bet vasarā sasniedz līdz 44 ha (Lovari et al., 2017) . Guļvietu atkārtoti stirnas parasti neizmanto, izņemot vēlā ziemā. (Tauriņš, 1982) (Macdonald, 2001)

Stirnas ir augēdāji un pārtiek no plaša augu diapazona. Veģetācijas sezonā stirnu pamatbarība ir zālaugu sulīgas daļas, pēc veģetācijas sezonas to barību galvenokārt sastāda sīkkrūmi. Augstas sniega kārtas gadījumā stirnas sāk baroties ar kokaugu mizu. Lauksaimniecību kultūrās pārtiek no sarkanā āboliņa, ziemāju zelmeņa, āboliem, lupīnām. Diennaktī viena stirna mēdz apēst no 2-3 kg barības.

Stirnas ir aktīvas visu gadu. Diennakts aktivitātes cikls vasaras periodā visaugstākais ir ap saulrietu un saullēktu, bet ziemā un agrā pavasarī barību biežāk meklē arī dienā. Stirnas dzīvo mātes ģimenēs, grupās vai kā vientuļnieki, it īpaši tēviņi ārpus riesta perioda. Parasti stirnas lielas grupas neveido vai tās ir īslaicīgas, izņemot agros pavasarī var koncentrēties 25 un vairāk īpatņi. Rudenī grupas veido no 2 līdz 4 īpatņiem. Savā teritorijā pārvietojas pa noteiktiem maršrutiem, un iemin takas. Dziļa sniega laikā pārvietošanās ir apgrūtināta, un kritiskais sniega segas biezums ir 35-40 cm. (Macdonald, 2001)

Stirnas ir poligāma suga, bet riesta periodā var izveidoties arī pāri. Starp tēviņiem ir novērojamas cīņas, un viens tēviņš var apaugļot vairākas mātītes. Riesta periods ilgst ap mēnesi un notiek jūlijā vai augustā. Grūtniecība ilgst ap 280 dienām, un vienā metienā var būt 1-3 mazuļi. Mazuļi tiek zīdīti līdz 3-5 mēnešu vecumam, un ar māti dzīvo līdz nākamā gada pavasarim. Jau sākot ar pirmajām dienām, stirnu mazuļi prot labi slēpties, un sāk sekot mātei no aptuveni 7 dienu vecuma, un no mēneša vecuma sāk pārtikt no augu barības. Stirnu mazuļu plankumi pazūd ap 3-4 mēnešu vecumu, un dzimumgatavību mātītes sasniedz 1 gada, bet tēviņi - 2 gadu vecumā. (Tauriņš, 1982)

Galvenokārt socializējas ar skaņas, vizuāliem un ķīmiskiem signāliem (urīna, ekskrementu, dziedzeru sekrēti). (Tauriņš, 1982)

Pēc VMD uzskaitēm, Latvijā no 1997. līdz 2009. gadam īpatņu skaits strauji palielinājās, no 38 419 līdz 240 204 īpatņiem (+525,22%), bet tad divu gadu laikā no 2009. līdz 2011. gadam, īpatņu skaits samazinājās gandrīz uz pusi, no 240 204 līdz 136 774 īpatņiem (-43,06%). Īpatņu skaita samazinājumu ietekmēja dažādi iemesli kā ziemas ar dziļu sniega kārtu, lielos daudzumos un viegli pieejama nepiemērota barība, un medniecība. Lai gan populācijas skaits būtiski samazinājās, Latvijā suga nevienā brīdī netika uzskatīta par apdraudētu. Nākamajos piecus gadus, no 2011. līdz 2016. gadam, īpatņu skaits Latvijā būtiski nemainījās, bet kopš 2016. gada līdz 2021. gadam ir novērots populācijas pieaugums, no 133 000 līdz 201 000 īpatņiem (+51,13%). Stirna ir vienmērīgi izplatīta visā Latvijā (2021. gadā).

1.1.3 Aļņi (*Alces alces*)

Aļņi ir raksturīgi Holarktiskajiem taigas biotopiem, kas pielāgojušies dzīvei gan boreālos mežos un kultūrainavā, bet arī daļēji stepēs vai tundrā. Tie apdzīvo plašu areālu kas aptver visu Eirāzijas un Ziemeļamerikas boreālo zonu. Latvijas teritorijā aļņi ir parādījušies vēlā leduslaikmetā, agrā holocēnā reizē ar subarktisko bērzu-priežu mežu veidošanos. To fosilās atliekas atrastas lielākajā daļā vidējā un vēlā akmens laikmeta Latvijas pirmiedzīvotāju nometnēs. Klimata izmaiņu dēļ, aļņa izplatības areāla dienvidu robeža virzījās uz ziemeļiem un tas izzuda no centrālās un rietumu Eiropas. Aļņu skaits piedzīvoja samazināšanos, un pēc pirmā pasaules kara tas Eiropā atradās uz izzušanas robežas, saglabājot stabilas populācijas tikai taigas tipa skujkoku mežos Ziemeļeiropā. Latvijā šajā periodā bija palikuši tikai ap 100 indivīdiem Vidzemes mežos. Ar 1920. gadu aļņa populācijas sāka palielināties, un to skaits sāka pieaugt. (Tauriņš, 1982)

Latvijā lielākā briežu dzimtas suga, tēviņi var sasniegt 300 cm garumu ar skausta augstumu līdz 205 cm, un mātītes 250 cm garumu un skausta augstumu līdz 190 cm. Tēviņu svars līdz 600 kg un mātīšu līdz 400 kg. Apmatojums sastāv no rupjiem akotmatiem un biezu pavilnu. Aļņiem ir melna muguras viduslīnija un tumši brūna mugurpuse un sāni. Purns un kājas ir gaiši rūsganas vai rūsgani pelēkas. Vēders un kāju iekšpuses ir baltas. Uz kakla un skausta ir pagarināti akotmati jeb krēpes, un pakaklē ir ādas kroka ar pagarinātiem matiem ko mēdz dēvēt par bārdū. Mazuļi ir rūsgani pelēki, bez plankumiem. (Spura, 1974)

Aļņi ir plastiska un eiribionta suga, kas no tradicionālās taigas ainavas ir pielāgojies dzīvei dažādos meža biotopos un kultūrainavās. Par pastāvīgām mītnēm tas izvēlas aizaugušus izcirtumus, veģetācijas periodā arī zāļu un sūnu purvus, ūdenstilpju piekrastes, krūmiem aizaugušas lauces un pļavas. Periodos bez veģetācijas tas uzturas priežu jaunaudzēs, un lapu koku audzēs ar lielu barības bāzi. Aļņa galvenā barības bāze ziemā bija vietas, ko skāruši meža ugunsgrēki, bet attīstoties antropogēnai mežsaimniecībai tās tagad ir jaunaudzes un priežu mežu kultūras. (Macdonald, 2001)

Aļņi ir nometnieks, dzīvo nelielās grupās, mātes ģimenēs vai vientuļi. Barus lielākoties veido govys ar 1-2 teļiem, vecāki tēviņi ārpus riesta perioda dzīvo atsevišķi, un jaunie īpatņi var dzīvot mazās grupās no 2-4 īpatņiem. Liela grupēšanās var tikt novērojama bargās ziemās pie izdevīgas barības bāzes, kur var tikt novēroti līdz 10 un vairāk īpatņiem. Aļņu diennakts cikls vasarā ir aktīvākais ap saullēktu un saulrietu, bet ziemās barību meklē arī dienas laikā. Dzīvnieki ir aktīvi visu gadu. Liela populācijas blīvuma gadījumā, notiek jauno īpatņu emigrācija, kurus mātes ir padzinušas. Tādā veidā jaunie īpatņi iemītnās jaunās teritorijās un bieži iemaldas arī pilsētvidē. (Tauriņš, 1982)

Aļņa individuālais izplatības areāls variē atkarībā no gadalaika. Vislielākie tie ir rudenī, kad pārgājēju garumi pārsniedz 6 km, bet vismazākie tie ir ziemas laikā, kad nepārsniedz 0,5–3,5 km, un to areāli ir no 900 līdz 1400 ha (Lovari et al., 2017; Tauriņš, 1982).

Poligāma suga, bet harēmi reti kad sastāv no vairāk par 3 govīm, parasti gadījumos, kad ir liels populācijas blīvums un govju īpatsvars. Bullis noteiktu laiku uzturas ar vienu govi, un tad sameklē citu. Nopietnas cīņas starp buļļiem notiek reti. Riests ilgst no augusta līdz septembra beigām, un grūsnība ilgst 8 mēnešus. Metienā lielākoties 1-2 mazuļi, dzimst nākamā gada maijā vai jūnija sākumā, un dzīvo kopā ar māti līdz nākamā gada pavasarim. Populācijas pieaugums ir galvenokārt atkarīgs no govju skaita populācijā. Govis dzimumgatavību sasniedz 2-3 gadu laikā, buļļi – 3 gados. Dzīves ilgums ir 18-20 gadi. (Tauriņš, 1982)

Pēc VMD uzskaitēm, Latvijā no 1994. līdz 1996. gadam īpatņu skaits samazinājās, no 8 694 līdz 6 646 īpatņiem (-23,56%), bet kopš tā brīža, īslaicīgi stabilizējoties no 2003. līdz 2008. gadam, ir piedzīvojis konstantu kāpumu no 6 646 īpatņiem līdz 23 000 īpatņiem 2021. gadā (+246,08%). Alnis ir izplatīts visā Latvijā, ar populācijas blīvuma gradienta pieaugumu austrumu virzienā, un izteikti lielāku populācijas blīvumu Vidzemes augstienē un Austrumlatvijas zemienē (2021. gadā).

1.1.4 Meža cūkas (*Sus scrofa*)

Pirmo reizi Latvijas teritorijā meža cūkas ieviesās boreālā klimata periodā agrā holocēna otrajā pusē, to fosilijas atrastas vairākos Latvijas pirmiedzīvotāju fosilajās skeleta atliekās. Līdz pat 18. gs. Latvijas teritorijā skaitījusies bieži sastopama suga, bet, sākot ar 18. gs.. īpatņu skaits samazinājies, un 19. gs. suga vairs netika uzskatīta pastāvīgu Latvijas faunas elementu. Izplatības areāla paplašināšanās Latvijā atsākās 19. gs. beigās un 20. gs. sākumā, Latvijas teritorijā ziemeļu robeža sasniedza Daugavu 1920. gados un 1940. gados suga bija sastopama visā Latvijas teritorijā un Igaunijas dienvidos. Tagad tā ir plaši izplatīta visā Latvijā un sugas areāls turpina paplašināties uz ziemeļiem (Tauriņš, 1982, Johann et al., 2020).

Meža cūka ir lielākais cūku dzimtas dzīvnieks, tēviņi sasniedz 210 cm garumu un svaru līdz 200 kg, mātītes sasniedz 170 cm garumu un svaru līdz 125 kg. Mežacūkai ir samērā īss, masīvs ķermenis, kurš ir nedaudz sāniski saplacināts, un īss kakls. Rets un rupjš ķermeņa apmatojums, kas sastāv no sarveidīgiem akotmatiem, kas visspēcīgāk attīstīti skausta un muguras apvidū. Ziemā apmatojums ir garāks, un zem akotmatiem attīstās brūna, īsa, bieza pavilna. Ķermeņa krāsojums var būt mainīgs – no pilnīgi melnas, melnbrūnas, līdz gaiši pelēkbrūnai (Spura, 1974). Meža cūka ir rietumpalearktiskas platlapju mežu faunas elements,

kurai ir plastisks dzīvesveids un tā ir pielāgojusies dzīvei borēalo mežu, meža stepju un stepju zonās. Visēdāja suga, galvenokārt barību iegūst, rokoties augsnē. Nozīmīgākie barības avoti ir augu saknes, bumbuļi, sīpoli, augsnes fauna kā sliekas un kukaiņu kāpuri. Galvenās uzturā lietotās lauksaimniecības sugas ir kartupeļi, pākšaugi, kukurūzas un vasarāju graudus. Kad augsne ir dziļi sasalusi, tad dzīvnieki cieš badu un var masveidīgi iet bojā (Tauriņš, 1982).

Apdzīvo dažādus mežus un pusatklātas ainavas, kalnos var dzīvot līdz 3000 - 4000 m augstumam virs jūras līmeņa. Izplatību ziemeļu virzienā limitē sniega segas un augsnes sasaluma dziļums, un barības pieejamība ziemas periodā. Ģimenes grupas vislielākās ir veģetācijas periodā, diennakts barošanās pārgājieni sasniedz 8 km vai vairāk. Rudenī tie var sasniegt 15 km vai vairāk. Ziemas laikā teritorija samazinās aptuveni no 0,8 km² līdz 2,5km², un barības pārgājienu attālums ir atkarīgs no sniegas segas dziļuma. Ziemas laikā piebarošanas vietās meža cūkas var atrasties lielā koncentrācijā no plašākas apkārtnes (Tauriņš, 1982, Johann et al., 2020).

Meža cūkas ir nometnieki, saistība ar teritoriju ir izteikta tikai vairošanās periodā, galvenokārt mātēm ar sivēniem. Ziemas laikā pieauguši tēviņi guļ vieni, mātītes guļ ar sivēniem. Vasarā un rudenī diennakts cikls ir izteikts ar lielāko aktivitāti krēslā-naktī, bet pavasarī un ziemā mātītes ar mazuļiem barību biežāk mēdz meklēt arī dienā. Meža cūkas ir bara dzīvnieki, barus veido mātītes un dažāda lieluma jauno īpatņu grupas. Rudeņos un ziemās vairākas ģimenes var apvienoties kopā. Baru vienmēr vada mātīte, bet to noslēdz kāds vecāks tēviņš. Baru lielumi vislielākie ir ziemā, kad tie var sasniegt līdz 30 īpatņiem, bet visbiežāk ir 6 līdz 10 īpatņi. Rudens baru lielums parasti ir 2-4 īpatņi (Macdonald, 2001).

Dzīvnieki ir poligāmi, viens pieaudzis tēviņš apaugļo 1-3 mātītes, riests ilgst 1 līdz 1,5 mēnešus, un parasti notiek starp Novembri un Janvāri. Starp tēviņiem ir novērojamas cīņas. Grūsnība ilgst no 110-140 dienām, un viena mātīte atkarībā no uzbarotības var dzemdēt 2-12 īpatņus, bet visbiežāk 5 līdz 6. Mazuļi dzimst no Marta beigām līdz Maijam. Mazuļi tiek baroti ar pienu līdz 3,5 mēnešiem, bet jau no 2 nedēļu vecuma var sākt mācīties meklēt barību augsnē. Dzimumgatavību mātītes sasniedz 18 līdz 20 mēnešu vecumā, bet labu apstākļu gadījumā var tikt apaugļotas arī 9 līdz 10 mēnešu vecumā. Sliktu apstākļu gadījumā riests var iekavēties un līdz pat 50% mātīšu palikt neapaugļotas. Tēviņi dzimumgatavību sasniedz jau no 3 gadiem, bet riestā galvenokārt piedalās sākot 4-6 gadu vecumā, jo vecāki tēviņi jaunākos padzen. Meža cūkas var brīvi vairoties ar mājas cūkām (Tauriņš, 1982).

Galvenokārt orientējas, izmantojot ožu un dzirdi, redze ir vājāk attīstīta. Viegli pārvietojas mitrās vietās, bet dziļa sniega gadījumā pārvietošanās ir apgrūtināta. Labi peld.

Mātītes var būt agresīvas, it īpaši, kad tām ir sivēni. To galvenie dabīgie ienaidnieki ir vilks un lācis, bet sivēniem uzbrūk arī lapsa un lūsis (Spura, 1974, Tauriņš, 1982).

Pēc VMD uzskaitēm, Latvijā no 1996. līdz 2013. gadam ir bijis konstants skaita pieaugums, no 17 636 līdz 74 107 īpatņiem (+320,20%). Pēc tam līdz 2018. gadam Latvijas mežacūku populācijas skaits strauji kritās no 74 107 līdz 20 000 īpatņiem (-73,01%), kad dēļ Āfrikas cūku mēra izplatīšanās Eiropā mežacūkām tika paaugstināta gan dabīgā mirstība, gan medniecība populācijas kontroles vajadzībām, cilvēku saimnieciskās darbības zaudējumu mazināšanai (Chenais et al., 2019, Dixon et al., 2019). No 2018. līdz 2021. gadam atkal ir bijis populācijas pieaugums, no 20 000 līdz 26 000 īpatņiem (+30,00%). Mežacūka ir izplatīta visā Latvijā, ar visaugstāko populācijas blīvumu Vidzemes augstienē un Austrumlatvijas zemienē (2021. gadā).

1.2 Pārnadžu nozīme un ietekme uz ekosistēmām

Veselīgas pārnadžu populācijas ir nozīmīgs faktors ilgtspējīgu un daudzveidīgu ekosistēmu nodrošināšanai. Pārnadžiem ir tieša ietekme uz apkārtējo vidi un tās darbībām, un tie mēdz tikt dēvēti par ‘vides inženieriem’ (Smit, 2011). Pārnadžu populācijas dabīgās ekosistēmās regulē mežu vecuma un sugu struktūru, un veido atvērtas mežu lauces, kas ir nepieciešamas sugu daudzveidības nodrošināšanai (Apollonio et al., 2017). Pārnadžiem kā medījumam ir būtiska ietekme plēsēju populāciju ieviešanai un saglabāšanai Eiropā, kā arī medniecības industrijā (Putman et al., 2011a). Savukārt pārlietu lielas pārnadžu populācijas var novest pie zaudējumiem mežniecībā, lauksaimniecībā, u.c. saimniecības sfērās. Populācijas tiek uzskatītas par neveselīgi lielām, kas tās negatīvi 1) ietekmē cilvēka dzīvi vai iztiku 2) sugas pielāgotību 3) samazina blīvumu citai sugai ar ekonomisku vai estētisku vērtību 4) padara ekosistēmu mazāk funkcionālu vai nefunkcionālu (Caughley, 1981).

Eiropas pārnadžu populācijas izplatīšanos un palielināšanos pēdējās desmitgadēs ir ietekmējuši daudzi faktori – palielināta urbanizācija, medību un dabīgo plēsēju samazināšanās, antropogēnie faktori, globālā sasilšana, pārnadžu plastiskums, vairošanās sekmes un reintrodukcija dažādos reģionos (Apollonio et al., 2014; Carpio et al., 2017; Caughley, 1981; Hindrikson et al., 2017; Tucker et al., 2018; Valente et al., 2020).

No pārnadžiem, Eiropā vislielākos zaudējumus lauksaimniecībā nodara meža cūka, ik gadu izmaksājot vismaz 80 miljonus eiro zaudējumos (Putman et al., 2011) un sastādot vairāk kā 90% no visiem lauksaimniecības zaudējumiem Itālijā un Horvātijā (Kusak & Krapinec, 2010). Pārnadžu postījumi mežsaimniecībā Eiropā pārsniedz 400 miljonus eiro gadā (Putman et al., 2011).

Pārnadži ir sugas, kuras visbiežāk iekļūst ceļa satiksmes negadījumos (CSN). Spānijā CSN ar meža cūkām un briežiem no 2006-2012. gadam palielinājās par attiecīgi 3600% un 300% (Sáenz-de-Santa-María & Tellería, 2015). Zviedrijā CSN ar meža cūkām ir palielinājušies par 600% (Thurfjell et al., 2015). CSN ar savvaļas pārnadžiem Slovēnijā, Francijā, Zviedrijā un Vācijā kopā ik gadu izmaksā vairāk nekā 650 miljonus Eiro (Valente et al., 2020). Pārnadžu izraisītie CSN izteikti korelē ar temporāliem un telpiskiem faktoriem, visbiežāk atgadījumi notiek rīta vai vakara krēslas stundās, kā arī pārnadžu pārošanās sezonas laikā rudens sākumā (Kušta et al., 2017).

Savvaļas pārnadžu populācijas blīvumam ir tieša ietekme uz slimību saglabāšanu un izplatīšanu lielākajai daļai pārnadžu slimību (Ruiz-Fons et al., 2014). Visizplatītākās pārnadžu slimības Eiropā ir dzīvnieku tuberkuloze, Aujeski slimība, un cūku mēris, kas ietekmē gan savvaļas, gan pieradinātas pārnadžu populācijas. No šīm visaktuālākā ir cūku mēris, kas Rietumeiropā izplatījās sākot no 1997. gada, un Latvijā galvenokārt no 2012. līdz 2015. gadam (Valente et al., 2020). Cūku mēris valstīs kā Spānija ir radījis pāri 100 miljonu Eiro zaudējumu, un Nīderlandē 1800 miljonu Eiro lielus zaudējumus, un joprojām ir novērojams noteiktās savvaļas meža cūku populācijās (Valente et al., 2020).

1.3 Pārnadžu populāciju izpētes metodes

Lai gan pārnadžu populācijas lieluma, blīvuma, demogrāfijas u.c. parametru novērtēšana ir salīdzinoši triviāls process atvērtās un izolētās teritorijās bez īpašiem ģeogrāfiskiem šķēršļiem, piemēram uz salām (Lowe, 1969), slēgtas un grūtāk apsekojamās teritorijās pārnadžu dzīvesveids ir slēpts, un precīzs populācijas novērtējums kļūst par sarežģītu procesu. Andersen (1953) pētījumā par stirnu populācijām teritorijā ar aktīvu medniecību tika aplēsti ap 70 īpatņiem, bet pēc visu dzīvnieku izšaušanas kopā tika uzskaitīti 213 īpatņi. Tradicionālas pārnadžu populācijas uzskaites metodes biežāk populācijas lielumus novērtē par zemu nekā par augstu (Caughley, 1974, Focardi et al., 2002, Kie, 1988), un metodes var nebūt pietiekami precīzas, lai ar tām spētu novērtēt ikgadējās populācijas izmaiņas (Smart et al., 2004).

Šajā sadaļā es iedalu pārnadžu uzskaites metodes divās kategorijās - tradicionālās un attālinātās metodēs. Tradicionālās metodes ietver ekskrementu (Kie, 1988) un pēdu (Dzięciołowski, 1976) uzskaites, dzinēju uzskaites (Dzięciołowski et al., 1995), transekšu uzskaites no zemes (Focardi et al., 2002) vai lidaparātiem (Caughley, 1974), un nomedīto dzīvnieku uzskaites (Appolonio et al., 2010). Pie tehnoloģiskajām metodēm ir apskatītas meža

kameras (LaFleur & Pebsworth, 2017) un bezpilota lidaparātu (Mulero-Pázmány et al., 2014, Witczuk et al., 2018) uzskaites.

Līdz ar tehnoloģiju attīstību ekoloģisko procesu izprašanā tiek arvien vairāk izmanto tehnoloģiskās metodes, kuras prasa mazāku cilvēku-resursu daudzumu uzskaites laikā un ir vieglāk uzstādāmas, tādējādi samazinot kopējās izmaksas datu ievākšanā un ekspertu trenēšanā (Witczuk et al., 2018), bet no otras puses tās uzkrāj vairāk datu, kuru analīze var būt sarežģīta un laikietilpīga (Forsyth et al., 2022).

1.3.1 Tradicionālās metodes

Ekskrementu uzskaites ir vienas no visizmantotākajām metodēm pārnadžu populāciju novērtēšanā (Kie, 1988). Šo metodi pirmo reizi aprakstījis (Bennett et al., 1940) un kopš tā laika tā ir tikusi plaši izmantota un atdzīta kā pietiekams indekss patiesās populācijas novērtējumiem (Kie, 1988, Eggert et al., 2003, Koster & Hart, 1988). Ekskrementu uzskaites ir vispiemērotākās sugām, kuras izkārnās vairāk, kamēr ir aktīvas, un neizvēlas noteiktus punktus, kuros izkārnīties (Smith, 2012). Mežacūku izkārnījumi arī var tikt uzskaitīti, bet to datu ievākšana var būt apgrūtināta dēļ to tendence uzrakt zemes virsmu (Tack, 2018). Ekskrementu uzskaites metožu galvenie plusi ir: nepieciešams mazs apmācības līmenis, ir viegli savienojama ar citām uzskaites metodēm, ir atkarīga, izmantojama daudzās dzīvotnēs, kā arī iespējams veikt DNS analīzi. Mīnusi ir nepietiekama variācijas novērtēšana, kā arī ekskrementu uzskaites ir nogurdinoša, tāpēc rezultātu precizitāte ir atkarīga no eksperta motivācijas (Smith, 2012).

Dzīvnieku pēdu uzskaites vēsturiski arī ir tradicionālā netiešā uzskaites metode, kas plaši izmantota vairākām pārnadžu sugām gan Eiropā, Amerikā, Āzijā un Āfrikā (Dzięciołowski, 1976, Keeping & Pelletier, 2014). Šīs uzskaites metodes pielietojamība bieži ir atkarīga no zemes substrāta, un tās pielietojums ir atvieglots ziemas apstākļos, kad zeme ir klāta ar sniegu un pēdu nospiedumi ir viegli pamanāmi. Dzīvnieku pēdu uzskaites tiek izmantotas vairākām dzīvnieku sugām, ieskaitot visas pārnadžu sugas. Pēdu uzskaites galvenokārt tiek izmantotas relatīvo populācijas lielumu vai indeksu noteikšanā, vai arī populācijas telpiskā izkārtojuma noteikšanā (D'Eon et al., 2006), bet, izmantojot noteiktus pieņēmumus, tās arī var tikt izmantotas dzīvnieku blīvuma noteikšanā (Keeping & Pelletier, 2014). Dzīvnieku pēdu uzskaites ir galvenā pārnadžu populācijas uzskaites metode Latvijā, Lietuvā, Igaunijā, un Rumānijā, un iepriekš arī Polijā (Appolonio et al., 2010).

Dzinēju uzskaites parasti norisinās dienas laikā, kad dzinēji līnijā iet caur meža nogabalu un izdod skaņas skaņas un izbiedē dzīvniekus, kuri bēg prom no teritorijas. Tos uzskaita skaitītāji, kuri ir novietoti apkārt pētāmajai teritorijai. Tādējādi ir iespējams noteikt

populācijas blīvumu, un kopējo skaitu nosaka ekstrapolējot iegūto dzīvnieku skaitu teritorijā uz kopējo teritoriju (Dzięciołowski et al., 1995, Borkowski et al., 2011). Dzīšanas uzskaites var būt piemērotas, ja kopējās populācijas novērtējums var variēt 20% robežās (Borkowski et al., 2011). Lai gan dzīšanu uzskaites veikšanai nav nepieciešama liela apmācība, ir nepieciešami apmācīti procesa koordinatori un liels skaits cilvēku, kas liek šim procesam veltīt lielu skaitu cilvēkstundu (Borkowski et al., 2011). Tās arī ir invazīvas un var ietekmēt vietējo dzīvnieku populācijas uzvedību, it īpaši teritorijās ar mazu antropoloģisko ietekmi (Witczuk et al., 2018). Dzinēju medības ir bieži izmantots pārnadžu populācijas izpētes veids vairākās Eiropas valstīs (Borkowski et al., 2011; Witczuk et al., 2018).

Nomedīto dzīvnieku skaits tiek izmantots kā relatīvs populācijas indeksa lielums vairākās Eiropas valstīs, kā Zviedrijā, Norvēģijā, Somijā, Vācijā, Austrijā, Ungārijā un Portugālē (Appolonio et al., 2010), bet arī citās valstīs (Imperio et al., 2010). Nomedīto dzīvnieku skaits ne vienmēr ir atkarīgs tikai no dzīvnieku populācijas lieluma, tas ir atkarīgs arī no medību intensitātes. Nomedīto dzīvnieku skaits uz medību dienu var tikt izmantots kā indekss populācijas noteikšanai, bet nomedīto dzīvnieku skaits ne vienmēr korelē ar populācijas lielumu skaitu starp dažādām sugām (Imperio et al., 2010, Wiebke et al., 2020).

Tieši dzīvnieku novērojumi var tikt veikti transektēs vai nu ar kājām vai arī ar lidaparātiem, vēl papildinot ar termālo attēlu iegūšanu, kas potenciāli uzlabo detektēšanas iespējamību naktī (Havens et al., 1998). Apvienojot šīs metodes ar attālumu paraugošanu, ir iespējams noteikt arī populācijas absolūtos lielumus un kļūdu intervālus. Tiešās uzskaites ir vispiemērotākās atklātās ainavās bez ģeogrāfiskiem šķēršļiem, kas uzlabo novērošanas iespējamību.

Tiešās uzskaites no gaisa var tikt veiktas gan ar fiksētu spārnu lidaparātiem, gan ar rotorplāniem, bet lidaparātu izmantošana uzskaitēs parasti ir dārga, un uzskaites kvalitāte ir atkarīga no vairākiem papildus faktoriem, kā pilota prasmēm, dzīvotnes piemērotības, un arī uzskaites veicēja pieredzes (Caughley, 1974). Uzskaites no lidaparātiem parasti novērtē zemākas dzīvnieku populācijas nekā reāli, un ja netiek ņemta vērā papildus faktori kā dzīvnieka 'novērojamība', tad šo uzskaites datus var izmantot kā populācijas indeksus. Dzīvnieka novērojamība ir atkarīga no dažādiem faktoriem, kā veģetācijas daudzuma, ģeogrāfiskajiem un temporāliem apstākļiem, laikapstākļiem (J G Kie, 1988). Uzskaitēm no lidaparātiem precizitāte samazinās, palielinoties lidojuma ātrumam, augstumam (Caughley, 1974). Uzskaitīto aļņu skaits pat ideālos apstākļos Aļaskas mežā nerasniedza 70% (LeResche & Rausch, 1974). Novērtējot pārnadžu populācijas no lidaparātiem, ir nepieciešams samazināt iespējamo kļūdu,

palēlinot lidojuma ātrumu, lidojot zemu, un laikā, kad dzīvnieki ir vispamanāmākie (LeResche & Rausch, 1974).

Populāciju novērtēšana no zemes parasti ietver zināmas distances noiešanu, un visu pamanīto īpatņu, un to perpendikulārā attāluma noteikšanai līdz transektes līnijai vai novērotāja atzīmēšanu. Šāda veida novērojumi parasti tiek veikti uz kājām, bet pārnadžu uzskaitēm ir izmantoti arī zirgi (Kucera, 1976), vai automobiļi (John G. Kie & White, 1985), ja tos ir iespējams izmantot pētījuma teritorijā. Ar šīm uzskaitēm var veikt absolūtās populācijas novērtējumus, bet tie balstās uz pieņēmumiem, ka dzīvnieka novērojamība ir atkarīga no attāluma līdz transektei, un ka visi indivīdi uz uzskaites līnijas ir pamanīti, tādējādi modelējot pārklāto teritoriju, kurā novērojuma iespējamība ir atkarīga no distances. Šo modekļu attālumu funkcija parasti atbilst negatīvi-eksponenciālai līknei (Focardi et al., 2002, Buckland et al., 2011).

1.3.2. Attālinātās metodes

Pēdējo divdesmit gadu laikā ir attīstījušās un dzīvnieku izpētē izmantotas divas nozīmīgas tehnoloģijas - bezpilota lidaparāti, un termālā infrasarkanā (TIR) attēlapstrāde. Jau 1968 gadā ziemas laikā izmantojot TIR kameras spēja detektēt 98 no 101 briežiem lidojot no 305 m augstuma (Croon et al., 1968). Samazinoties TIR sensoru izmaksām un arī izmēriem, tie ir vieglāk pieejami dažādiem ekoloģiskiem pētījumiem (Havens & Sharp, 2015). Bezpilota lidaparāti pilda līdzīgu lomu kā tradicionāli lidaparāti, novērojot dzīvniekus no gaisa. Lai gan bezpilota lidaparāti nevar nosegt tik lielas teritorijas kā tradicionālie lidaparāti, tie ir lētāki, klusāki, spēj lidot zemāk, tiem nav nepieciešams lidlauks, lai paceltos un tos var programmēt tā, lai tie autonomi pārlidotu pāri mērķa teritorijām (Linchant et al., 2015). Bezpilota lidaparātiem nav nepieciešams pats pilots, kas novērš katastrofas risku kā tradicionāliem lidaparātiem, it īpaši lidojot zemas gaismas apstākļos, lēni un zemu (Witczuk et al., 2018). Bezpilota lidaparāti, izmantojot TIR sensorus, ir vispielietojamākie ziemas laikā virs atklātām vai lapkoku teritorijām, kad temperatūras kontrasts starp dzīvniekiem un fonu ir vislielākais, un apkārtējā veģetācija ir vismazākā (Linchant et al., 2015). Pirmo reizi bezpilota lidaparāti dzīvnieku novērošanai tika izmantoti 2006. gadā, kur tika izmantoti redzamās gaismas sensori uz gan rotora, gan fiksētu spārnu bezpilota lidaparātiem (Jones et al., 2006). Apvienojot bezpilota lidaparātus gan ar redzamās gaismas, gan ar TIR sensoriem, ir iespējams novērtēt absolūtās pārnadžu populācijas visos diennakts laikos un neatkarīgi no dzīvnieka fona (Witczuk et al., 2018). Tā kā dati, kas ievākti ar bezpilota lidaparātiem, tiek saglabāti, tos ir iespējams saglabāt un apstrādāt nenoteiktu laiku pēc lidojuma, tādējādi datu ievākšanas brīdī nav

nepieciešama augsti trenēta eksperta klātbūtne. Šo datu apstrādē var tikt izmantoti mašīnmācīšanās modeļi, tādējādi iespējamāk vēl samazinot potenciālo cilvēka kļūdu, un arī atvieglot datu apstrādes procesu nākotnē (Lhoest et al., 2015). Bezpilota lidaparāti ar TIR un redzamās gaismas sensoriem ir daudzsološs risinājums absolūtai pārnadžu populācijas novērtēšanai maza vai vidēja izmēra mēroga teritorijām, bet to pielietošanai ir nepieciešami papildus pētījumi, it īpaši konstatējamības koeficientu noteikšanā dažādās teritorijās, kā skujkoku mežos (Witczuk et al., 2018).

1.4 Meža kameras

Meža kameras jeb meža slazdi, ir kameras, kas parasti apvienotas ar kustības un pasīvi infrasarkanā (PIR) sensoru. Tās uzņem attēlu vai video brīdī, kad to redzes lauku šķērso silts un kustīgs objekts (Burton et al., 2015). Pirmās meža kameras briežu populācijas novērtēšanai tika izmantotas 1992 gadā (Lin, 1998). Pēdējo 20 gadu laikā tās ir kļuvušas par plaši izmantotu instrumentu dzīvnieku populāciju, izplatības, apdzīvotības u.c. faktoru novērtēšanai (LaFleur & Pebsworth, 2017) visos pasaules kontinentos (Forsyth et al., 2022, Kim et al., 2022).

Funkcijas, svarīgākie parametri

Pateicoties PIR sensoru aprīkojumiem, meža kameras ir vispiemērotākās dzīvniekiem, kuri paši izdala siltumu. Tās aktivizējas brīdī, kad objekts ar siltuma kontrastu pret apkārtējo vidi pārvietojas noteiktu attālumu tās redzes laukā, un tad uzņem pirms tam noteiktu skaitu attēlu, vai arī noteikta ilguma video. Šis attēls vai video tiek saglabāts atmiņas kartē, kas ievietota meža kamerā, fiksējot uzņemto datumu, laiku, meža kameras numuru, un atkarībā no kameras modeļa (LaFleur & Pebsworth, 2017). Atkarībā no modeļa, meža kamerām ir dažādi parametri, kā attēla vai video rezolūcija, attēla uzņemšanas ātrums, zibspuldzes attālums, PIR sensora attālums. No šiem parametriem var būt atkarīga pētījuma kvalitāte, un ir tie ir jāņem vērā pirms pētījuma uzsākšanas (Rovero et al., 2013).

Attēla uzņemšanas ātrums ir viens no vissvarīgākajiem faktoriem, jo tam ir būtiska loma tam, vai tas spēs uztvert dzīvniekus, kas ātri pārvietojas vai atrodas tuvu kamerai, kas noved pie 1. tipa kļūdām jeb viltus pozitīviem, kad attēls ir uzņemts, bet viņā nav novērojams dzīvnieks, un tādējādi attēls tiek uzskatīts par tukšu. Mūsdienās nopērkamām meža kamerām attēla uzņemšanas ātrums parasti ir no 0.2 – 0.6 s (Rovero et al., 2013). Lēna attēla uzņemšanas

ātruma kļūdas var samazināt, novietojot meža kameras tālu vai arī ne-perpendikulārā leņķī no vietas, pa kuru vistīcamāk pārvietosies dzīvnieks, tādējādi palielinot laiku, kuru dzīvnieks pavada kameras redzes joslā (Cusack, Dickman, et al., 2015).

Attēla vai video izšķirtspēja var būt svarīgs parametrs dzīvnieka klātbūtnes noteikšanā, it īpaši, ja dzīvnieks saplūst ar kameras redzeslauka fonu, vai arī redzeslauks ir ar sarežģītu struktūru. Zemākām izšķirtspējām ir lielākas tendences uz 1. tipa kļūdām. Mūsdienās lielākā daļa meža kameras piedāvā vismaz 3 MP dienas un 1 MP nakts izšķirtspēju, un vismaz 720p HD video izšķirtspēju (LaFleur & Pebsworth, 2017).

Zibspuldzes attālums un veids ir svarīgs 1. tipa kļūdu un arī dzīvnieku traucējumu samazināšanai. Meža kamerām ir pieejamas dažāda veida zibspuldzes, sākot ar redzamās gaismas līdz “No glow” infrasarkanajām zibspuldzēm līdz 980 nm, padarot tās neredzamas vai ļoti grūti pamanāmas lielākajai daļai zīdītāju (Rovero et al., 2013). Dzīvnieku traucējumu samazināšanai parasti tiek izmantotas tiem neredzamas zibspuldzes, bet noteiktos pētījumos, piemēram, dzīvnieku zīmējumu vai marķējumu atpazīšanai tiek izmantotas redzamās gaismas zibspuldzes (Wegge et al., 2004). Zibspuldzes intensitātei var būt būtiska ietekme 1. tipa kļūdu samazināšanai atklātās vietās, kur PIR sensors ir detektējis dzīvnieku un aktivizējis kameru, bet zibspuldze to nav apspīdējusi pietiekami daudz, lai tas būtu pamanāms (Rovero et al., 2013). Šāda veida kļūdas var novērst meža kameras novietojot slēgtākās vietās, kur dzīvnieks nevar šķērsot redzeslauku pārāk tālu.

PIR sensora detektēšanas attālums un jutība var būt būtiska funkcija dažādām meža kamerām. Lielākajā daļā meža kameru ir iespējams iestatīt PIR sensora jutības līmeni. Ja PIR sensors nav pietiekami jūtīgs, tad tas var palielināt 2. tipa kļūdas jeb viltus negatīvus, kas nozīmē, ka mērķa objekts ir bijis meža kameras redzes laukā, bet nav ticis detektēts (LaFleur & Pebsworth, 2017). Tā kā meža kameru dati tiek uzglabāti un pēc tam analizēti, izlabojot 1. tipa kļūdas, dzīvnieku pētījumos parasti uzstāda augstu PIR sensora jutību, tādējādi samazinot 2. tipa un 1. palielinot tipa kļūdu daudzumu (Cove et al., 2021).

Ir pieejami vairāki meža kameru modeļi ar datu pārraides iespējām pa mobilo tīklu. Lai gan šī funkcija nav būtiska kvalitatīvu datu nodrošināšanā, tā var būt ļoti noderīga it īpaši lielos un ilga laika posma meža kameru pētījumos. Meža kameras var pārraidīt datus, tādējādi parādot reāla-laika notikumus kamerās, vai arī pārraidīt kameras aktivitāti noteiktā laika periodā, bateriju daudzumu, atlikušo atminu, tādējādi nodrošinot laicīgu meža kameru apsekošanu un nepārtrauktas darbības nodrošināšanu (LaFleur & Pebsworth, 2017).

Meža kamerām ir vairākas priekšrocības, salīdzinot ar citām dzīvnieku uzskaites metodēm. Tās var ievākt lielus datu apjomus ilgos periodos bez apsekošanas. Salīdzinot ar,

piemēram, lamatām, viena meža kamera var veikt tūkstošiem dzīvnieku novērojumus (LaFleur & Pebsworth, 2017). Meža kameras izdod minimālu skaņu un gaismu, un tā kā tās neprasa biežu apsekošanu, tās ir neinvazīvākas par citām uzskaites metodēm, tādējādi ļaujot pētīt dzīvnieku uzvedību bez traucējumiem. Pateicoties lielajai autonomitātei, meža kameras var izmantot pētījumos grūti pieejamās vietās (Kim et al., 2022). Meža kameras spēj detektēt dzīvniekus arī tumsā, tāpēc tās var izmantot dzīvnieku pētīšanai arī tumšajā diennakts laikā (Mace et al., 1994). Meža kameru bildes saglabājas un var tikt analizētas jebkurā brīdī pēc to uzņemšanas, kas ļauj pārlicināties par datu pareizību. Datu ievākšana ir atkarīga no elektriska sensora, kas samazina cilvēka kļūda novērojamībā, piemēram, atkarībā no pētnieka pieredzes vai noguruma (Tabak et al., 2019).

Lai gan ilgtermiņā meža kameras var būt lētākas nekā citas metodes, tām ir nepieciešams samērā liels vienreizējs ieguldījums, lai iegādātos pašas kameras, baterijas un citu ekipējumu, it īpaši lielākiem pētījumiem (Rovero et al., 2013). Lieli un gari meža kameru pētījumi var ievākt ļoti lielus datu apjomus, kuru analīze var aizņemt ievērojamu laiku, it īpaši, ja tajās ir bijušas daudz 1. tipa kļūdas dēļ kāda pastāvīga, kustīga objekta kameras redzeslokā. Meža kameras var bojāt abiotiski apstākļi kā liels mitrums vai sals, biotiski faktori kā dzīvnieki, vai arī antropogēni faktori kā zādzība (Meek et al., 2019).

Meža kameras ir plaši tikušas izmantotas dzīvnieku sugu skaita un daudzveidības noteikšanā dažādās teritorijās (Tanwar et al., 2021), un dati, kas ievākti ar meža kamerām, ir devuši pierādījumus sugas areālu izmaiņām (Pettorelli et al., 2010) un pat jaunu sugu atklāšanā (Rovero & Rathbun, 2006). Meža kameras ir tikušas novērtētas kā potenciāli labāka metode dzīvnieku sugaskaita novērtēšanā par vairākām tradicionālām metodēm, kā pēdu uzskaitēm (Dupuis-Desormeaux et al., 2016, Ford et al., 2009), līniju transektēm (Li et al., 2012) u.c.

Meža kameras ir plaši tikušas pielietotas un ir atzītas kā precīza metode absolūtajam populācijas novērtējumam, izmantojot ķeršanas-kontroles (capture-recapture), iezīmē vai cita veida modeļus individuāli atpazīstamiem indivīdiem (Taylor et al., 2022), un nosaka absolūto populācijas lielumu atkarībā no tā, cik bieži viens un tas pats dzīvnieks tiek novērots katrā meža kamerā, tādējādi nosakot varbūtību, cik dzīvnieki no kopējās populācijas nav novēroti (Pollock, 1980). 'Mark-resight' metode bija pirmā metode, kas tika izmantota dzīvnieku absolūtās populācijas novērtēšanai izmantojot meža kameras (Mace et al., 1994). Absolūto populāciju noteikšana izmantojot meža kameras individuāli atpazīstamiem dzīvniekiem ir tikušas novērtētas kā potenciāli labāka metode par ekskrementu uzskaitēm ar DNS sekvenēšanu (Anile et al., 2014), līniju transektēm (Trolle et al., 2008) u.c.

Lai gan absolūtās populācijas novērtēšana ar meža kamerām ir ļoti efektīva un robusta metode sugām ar savstarpēji atpazīstamiem indivīdiem, absolūtās populācijas novērtēšana savstarpēji neatpazīstamiem dzīvniekiem ir liels izaicinājums (Gilbert et al., 2020). Ja dzīvnieki nav savstarpēji atšķirami, tad nav iespējams noskaidrot, vai vairāki novērojumi atbilst vienam vai vairākiem indivīdiem. Pēdējo 20 gadu laikā ir izveidotas dažādas metodes šīs problēmas risināšanai – N-mikstūru (Royle, 2004) un Royle-Nichols (Royle & Nichols, 2003) modeļi neatkarīgām lokācijām, Time-to-Event (Moeller et al., 2018), Random Encounter Models (Cusack, Swanson, et al., 2015), Unmarked Spatial Capture Recapture (Royle et al., 2013), Distance sampling (Howe et al., 2017) modeļi, bet tie pamatojas uz grūti piepildāmiem pieņēmumiem, kā nekādi viltus pozitīvi vai negatīvi dati, aktivitātes centri laika gaitā nemainās, dzīvnieki savā starpā nav saistīti, perfekta novērojamība u.c. atkarībā no metodes veida (Gilbert et al., 2020). Vairākiem modeļiem ir nepieciešama papildus informācija kā dzīvnieku kustības ātrums, attālums no kameras, un/vai meža kameras redzesloka noklātais laukums, kas padara to praktisko pielietojumu sarežģītu (Cusack, Swanson, et al., 2015; Howe et al., 2017; Royle et al., 2013).

Kā alternatīvu absolūtajiem populācijas novērtējumiem, dzīvnieku monitoringa nolūkos var izmantot relatīvo daudzuma indeksu (RDI) (Burton et al., 2015). RDI bieži vien tiek pieņemts kā novērotais dzīvnieku skaits laika intervālā, bieži vien uz 100 meža kameras dienām (Kitamura, 2015). Lai gan dzīvnieka novērojamība kā populācijas lieluma indekss ir bijis strīdīgs, jo dzīvnieka novērojamība nav konstanta atkarībā no kameras izvietojuma, sugas, dzīvnieka temporālās aktivitātes, lieluma, biotopa, un ārējiem faktoriem (Sollmann et al., 2013), empīriskos pētījumos tai ir pierādījusies liela korelācija ($r^2 = 0.80$) ar patieso briežu blīvumu (Parsons et al., 2017). RDI ir piemērots pētījumiem bieži sastopamu un neapdraudētu dzīvnieku sugām, no kura var iegūt ieskatu dzīvnieku temporālajā uzvedībā, biotopu izvēlē un izvietojumā, starp-sugu mijiedarbībā un ilglaicīgos populāciju trendos (Gilbert et al., 2020). Lai gan RDI ir robustāks sistemātiskos vai randomizētos meža kameru izkārtojumos, tas var korelēt ar patieso populācijas blīvumu un dot ieskatu vietējās dzīvnieku populācijās arī no meža kamerām ar subjektīvu izkārtojumu (Jenks et al., 2011; Tanwar et al., 2021). Lai mazinātu iespējamību, ka viens un tas pats dzīvnieks ir novērots vairākas reizes mazā laika sprīdī un palielinātu datu neatkarību, RDI parasti tiek aprēķināts interpretējot attēlu neatkarīgos notikumus. Lai viens notikums tiktu nošķirts no iepriekšējā, ir jāpaiet vai nu tiekami lielam laika periodam, vai arī jābūt novērotai citai dzīvnieku sugai (O'Brien et al., 2003). Lai gan izvēlētais laika ilgums, lai nošķirtu notikumus, var atšķirties, visbiežāk izvēlētais laika intervāls

starp vienas un tās pašas sugas indivīdiem ir 30 minūtes (Kitamura, 2015; O'Brien et al., 2003; Roque et al., 2021).

1.5 Mašīnmācīšanās modeļi

Mašīnmācīšanās ir datu analīzes metode, kas spēj veikt paredzējumus jauniem datiem, balstoties uz iepriekš dotiem piemēriem un pieredzēm (Mitchell, 1997). Tāpēc ka mašīnmācība neseko skaidri norādītām instrukcijām, mašīnmācīšanās algoritmi bieži tiek izmantoti procesos, kuros nevar norādīt precīzus konvencionālus parametrus pēc kuriem sekot, piemēram, kā e-pastu filtrēšanā, runas atpazīšanā, medicīnā, biznesā, meteoroloģijā u.c. (Géron, 2019; Mitchell, 1997; Scher & Messori, 2018). Mašīnmācīšanos var raksturot trīs veidos – pārraudzītajā, nepārraudzītajā un stimulētajā (Géron, 2019).

Uzraudzītā mašīnmācīšanās ir balstīta uz datu kopu, kurā katram datu punktam ir norādīta gan ievade ar noteiktiem parametriem, gan arī vēlamais rezultāts. Šī datu kopa tiek sadalīta divās daļās – apmācības un testa, kur apmācības datu kopai ir dota informācija gan par ievadi, gan par rezultātu, un testa kopai ir doti tikai ievades dati, bet rezultāts modelim nav dots. Izmantojot apmācības datu kopu, modelim ir jāiemācās kā informācija, kas ietverta ievades datu vērtībās, noved pie rezultāta (Géron, 2019; James et al., 2015; Mitchell, 1997). Uzraudzītās mašīnmācības modeļi var veikt regresijas, klasifikācijas uzdevumus, vai abu veidu šo uzdevumu savienojumu. Regresijas modeļi paredz nepārtrauktas vērtības, bet klasifikācijas modeļi iedala rezultātus kategorijās (Burger, 2018). Modeļa novērtēšanai tiek izmantota testa datu kopa, kurai modelis novērtē katra datu punkta rezultātu atkarībā no ievades datu sakarībām, kuras tas ir iemācījies apmācības laikā. Pēc tam modelis tiek novērtēts atkarībā no tā, cik tuvu tas ir prognozējis patiesos rezultātus (regresija), vai arī cik daudz kategorijas ir pareizi prognozējis (klasifikācija). Visbiežāk izmantotie uzraudzītās mašīnmācības modeļi ir lineārā vai loģistiskā regresija, lēmumu koki, atbalsta vektoru mašīnas (Géron, 2019).

Neuzraudzītā mašīnmācīšanās ir balstīta uz datu kopām, kurām ir tikai ievades dati bez norādīta vēlamā rezultāta, un neuzraudzītās mašīnmācīšanās algoritms atrod iekšējo datu struktūru (Patel, 2019). Visbiežāk izmantotie neuzraudzītās mašīnmācīšanās algoritmi ir grupēšanas, asociāciju meklēšanas vai dimensiju samazināšanas. Grupēšanā dati tiek sadalīti iepriekš noteiktās daļās, un pēc tam iedala iepriekš neredzētus datus grupās balstoties uz iepriekšējo ievades datu līdzībām (Mitchell, 1997). Asociācijas algoritmi tiek izmantoti dažādu attiecību atklāšanai starp datu kopas punktiem (Agrawal et al., 1993). Datu dimensiju samazināšanas algoritmi tiek izmantoti gadījumos, kad ievades datiem ir liels skaits dimensiju,

kas var novest pie grūtībām atrast sakarības ievades datus. Šis solis bieži vien tiek izmantots priekšapstrādē, lai samazinātu ievades datu apjomu lielām datu kopām (Géron, 2019).

Stimulētā mašīnmācīšanās ir algoritma veids, kurš stimulē fiziskajā pasaulē sastopamas problēmas, izmantojot pozitīvu vai negatīvu atgriezenisko saiti vairākās iterācijās, tādējādi balstoties uz apmācības un kļūdas metodi (Géron, 2019; Mitchell, 1997).

1.5.1 Dziļā mašīnmācīšanās

Dziļā mašīnmācīšanās ir mašīnmācīšanās apakšnozare, kura balstīta uz mākslīgo neironu tīkliem (Patterson & Gibson, 2017). Jau 1943. gadā McCulloch & Pitts (1943) izveidoja vienkāršu matemātisku modeli kurš darbojās uz līdzīgiem principiem kā bioloģiski neironi – tas aktivizē izvades signālu, kad ir aktivizējušās pietiekami daudz ievades signāli, lai pārsniegtu aktivizācijas sliekšni. Šajā rakstā arī tiek demonstrēts kā uzbūvēt vairāku mākslīgu neironu tīklu, lai izpildītu jebkuru loģisko funkciju.

Dziļā mašīnmācīšanās balstās uz vairākiem mākslīgo neironu tīklu līmeņiem, kuri iekšēji nosaka svarīgākos ievades parametrus pēc kuriem veikt prognozi (Buduma & Locascio, 2017). Šī iemesla dēļ dziļā mašīnmācīšanās ir plaši pielietota nestrukturētu datu kopu analīzei un paredzēšana gan attēliem, gan tekstam, gan skaņām u.c., bet tādējādi veido arī “melnās kastes” efektu, kas nerada izpratni par to kā modelis ir nonācis līdz rezultātam (Géron, 2019). Lai ar dziļo mašīnmācīšanos iegūtu labus rezultātus, ir nepieciešami lieli datu apjomi un datošanas jauda (Géron, 2019). Lai gan dziļās mašīnmācīšanās pamati ir izveidoti pirms gandrīz 80 gadiem, tā kļuva plaši pielietota un pētīta pēc 2012. gada, pēc tam kad (Krizhevsky et al., 2012) uzlaboja top-5 kļūdu intensitāti no 26,2% uz 15,3% etalona datubāzei ImageNet, izmantojot dziļās mašīnmācīšanās modeli (Yapıcı et al., 2019).

Mūsdienās ir izveidoti vairāki dziļās mašīnmācīšanās tīklu veidi kā konvulatīvie neironu tīkli (CNN), rekurentie neironu tīkli (RNN), ierobežotie Bolcmaņa-mehānismi (RBM) un autokodētāji (Autoencoders), visplašāk izmantotie dziļie neironu tīkli attēlu atpazīšanai ir konvulatīvie neironu tīkli (COŞKUN et al., 2017, Mikołajczyk & Grochowski, 2018). Konvulatīvie neironu tīkli ir balstīti uz smadzenīšu garozas vizuālās apstrādes reģiona uzbūvi (Géron, 2019; Hubel, 1959), un sastāv no vairākiem liela izmēra mākslīgo neironu tīkliem, kuri konverģējas un dod prognozēto rezultātu. Lai apmācītu un izmantotu šādus tīklus ir nepieciešams īpaši liela datošanas jauda, tāpēc to pielietojums ir palielinājies līdz ar datošanas jaudas uzlabojumiem. Tie ir izmantoti un sasnieguši augstus rezultātus tādās nozarēs kā attēlu un video atpazīšana (Simonyan & Zisserman, 2015, Karpathy et al., 2014), dabiskās valodas apstrādē (Duque et al., 2016), laikrindu paredzēšanā (He & Zhao, 2019) u.c. kompleksos

mašīnmācības uzdevumos. YOLOv5 modelis ir dziļās mašīnmācīšanās modelis, kurš būvēts uz vairāku modeļu savienojumu, un līdz šim ir sasniegjis vislabākos rezultātus objektu atpazīšanas jomā precizitātes un ātruma ziņā (Nepal & Eslamiat, 2022). Kā modeļa veiktspējas metrikas var izmantot dažādus parametrus, kā precizitātes-atdeves likni, kas reprezentē modeļa spēju atpazīt mērķa objektus no kopējās datu kopas (to mēdz arī apvienot vienā skaitlī, ko sauc par F mēru), vai arī mAP (mean Average Precision), kas ietver paredzējumu matricas, atdeves un precizitātes rezultātus (Géron, 2019).

1.6 Mašīnmācīšanās modeļu pielietojums pārnadžu pētīšanā ar meža kamerām

Kopā ar attālināto tehnoloģiju pielietojuma palielināšanos ekoloģiskajos pētījumos, ir būtiski palielinājies apstrādājamo datu apjoms (Gomez et al., 2017). Liela apjoma un ilglaicīgi pētījumi, kas izmanto meža kameras var sasniegt miljoniem attēlu (Swanson et al., 2015), kuru manuāla analīze var aizņemt ļoti lielu daudzumu cilvēklaiku (Norouzzadeh et al., 2018a). Pateicoties to iespējām risināt sarežģītus uzdevumus, dziļā mašīnmācīšanās pielietojumi meža kameru attēlu apstrādē ir strauji attīstījušies pēdējā desmitgadē (Miao et al., 2019).

Pirmais dziļās mašīnmācīšanās modelis tika izveidots 2014 gadā, kurā, izmantojot divpakāpju sistēmu, tika klasificētas 20 Ziemeļamerikā bieži sastopama sugas, sasniegdot 38,3% pareizību sugu atpazīšanā (Chen et al., 2014). Gomez (2017). Tas izmantoja dažādus dziļās mašīnmācīšanās tīklus, lai klasificētu 'Snapshot Serengeti' datu kopu, kura sastāvēja no 3.2 miljoniem attēlu no 225 meža kamerām, kuri saturēja 48 dažādas sugas. Ar ConvNet klasifikācijas modeli tika sasniegta 88,9% pareizība starp visām sugām, un atsevišķas sugas tika noteiktas ar lielāku pareizību nekā amatierzinātni. Gadu vēlāk, uz šīs pašas datu kopas, Norouzzadeh et al. (2018) izveidoja divpakāpju dziļās mašīnmācīšanās modeli, kurš sasniegta 93,8% pareizību dzīvnieku atpazīšanā, un 99,3% pareizību attēliem, par kuriem tas bija pārliecināts, pārsniedzot brīvprātīgo cilvēku 96,6% pareizību. Šo attēlu automātiska anotēšana aizstātu 17 000 eksperta stundu manuālā anotēšanā. Mūsu platuma grādos Tabak et al. (2019) izveidoja dziļās mašīnmācīšanās modeli no 3,7 miljoniem anotētu attēlu ar 27 klasēm, kurš sasniegta 97,6% pareizību uz testa datu kopas. Šis modelis pēc tam tika testēts ārpus sākotnējās datu kopas attēliem Kanādā, kur sasniegta 82% klasifikācijas pareizību. Visi šie modeļi izmanto kopējo attēlu, lai klasificētu dzīvniekus, bet klasifikācijas pareizība var tikt uzlabota iezīmējot dzīvniekus rāmjos ar vislielāko iespējamību tiem atrasties attēlos, un tad

klasificēt dzīvnieku šajā rāmī (Miao et al., 2019). Carl et al. (2020) izmantoja dziļās mašīnmācīšanas modeli ar diviem daļām un pirms tam trenētu datu bāzi dzīvnieku klasificēšanai Vācijā. Lai uzlabotu klasificēšanas rezultātus, dzīvnieki tika klasificēti augstākos taksonomiskos līmeņos, jo modelis nespēja atšķirt dzīvnieku sugas. Tas detektēja cūkas ar 100% pareizību, un briežus ar 94% pareizību. Choiński et al. (2021) izmantoja YOLOv5 struktūru uz 2 659 attēlu TRAPPER datu bāzes no Belovežas, Polijas. Tas klasificēja dzīvniekus 11 dažādās kategorijās, sasniedzot 85% F mēru (F1-score). Mašīnmācīšanās modeļa prognozēšanas spējas ir atkarīgas no tā, cik daudz līdzīgus apmācības datus tas ir redzējis, tādējādi pie sarežģītiem un mainīgiem foniem tā pareizība var kristies, ja tas nav ticis apmācīts uz līdzīgām datu kopām (Géron, 2019).

2 Materiāls un metodes


2.1 Pētījuma vietas raksturojums

Pētījums tika veikts no 2021. gada 1. janvāra līdz 2022. gada 1. janvārim. Pētījuma teritorija atrodas Cēsu rajonā, koordinātēs 57° 11' 20.22" N, 25° 29' 5.172" E, aptuveni 20 km uz dienvidaustrumiem no Cēsīm. Pētījuma teritorijas izmērs ir 1387.32 ha, no kuras 86% sastāda meži, 8% sastāda atvērtas ainavas kā pļavas un labības lauki, un atlikušos 6% sastāda izcirtumi, purvi u.c. veida teritorijas. No visiem mežiem 52% ir jaukti, kuros dominē bērzs *Betula* vai egle *Picea abies*, un atlikušie meži ir tīrkultūras ar egli vai bērzu. Jauni meži sastāda 55% un nobrieduši meži sastāda 45% visas mežu teritorijas. Pa visu meža teritoriju ir izvietotas 6 barotavas un aptuveni 20 sālsstabi, atkarībā no sezonas.

Teritorijā ir novērojama antropogēnā aktivitāte, kura var būt sadalāma trīs daļās – 1) bieža, regulāra, zema ietekme visas teritorijas platībā no vietējā mežziņa, teritorijas kopējiem, meža kameru apsekotājiem; 2) neregulāra, bet augsta atsevišķās teritorijās mežsaimniecības rezultātā; 3) regulāra, reta, un augsta medību sezonā. Teritorijā ir divi ceļa veidi – grants, kurus izmanto regulāri visi teritorijas apmeklētāji, un zemes, kurus neregulāri izmanto mežzinis vai mežsaimniecībā. Teritorija nav noslēgta, bet ceļu izmantošana ir atļauta tikai piederīgām personām.

2.2 Datu ievākšanas metodes

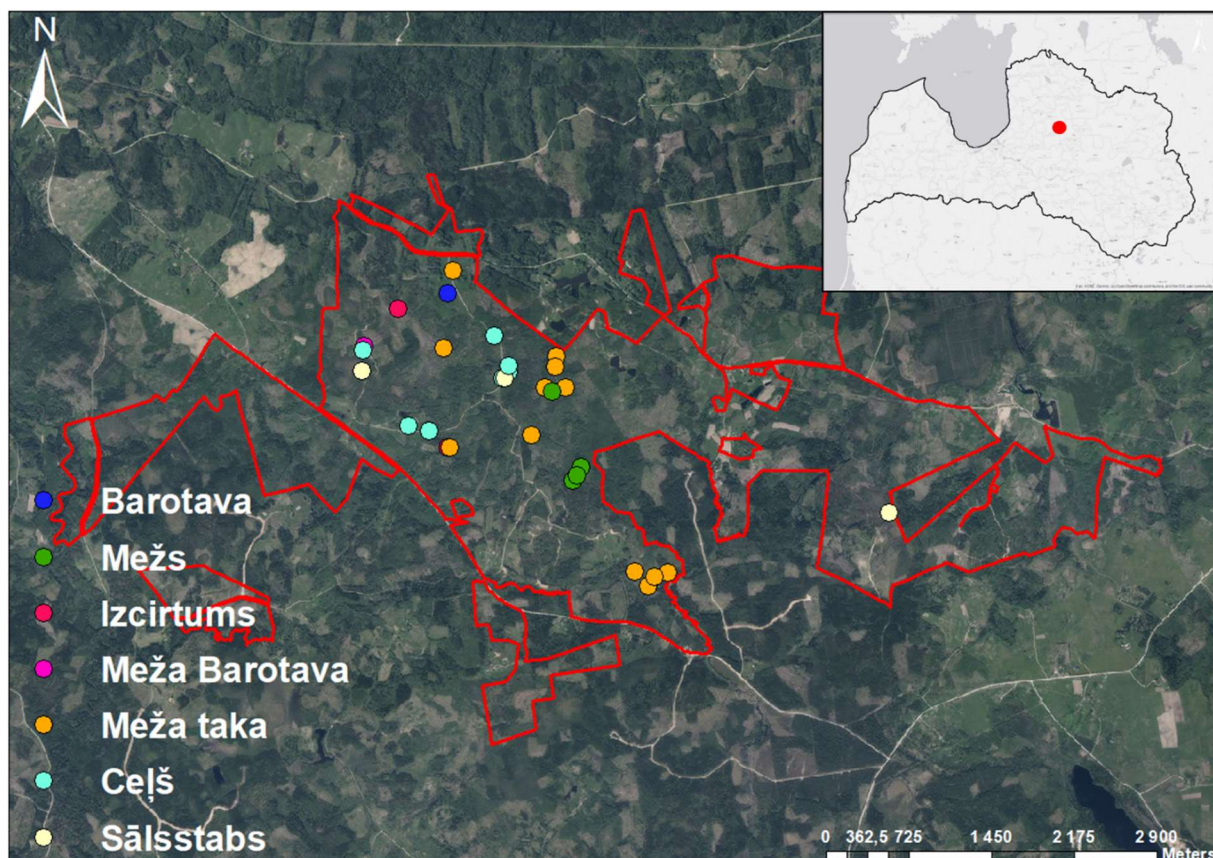
Pētījumā tika izmantotas automātiskās meža kameras Dörr SnapShot Cloud 4G (Dörr GmbH). Meža kameras tika iestatītas attēlu ievākšanas režīmā ar augstāko izšķirtspēju gan dienas gaišajā, gan tumšajā laikā. PIR sensora jutība tika iestatīta uz augstāko režīmu. Aktivizācijas brīdī meža kamera uzņēma 5 attēlus pēc kārtas, un minimālais laiks līdz nākamajai aktivizācijai bija viena minūte. Datu apjoma un meža kameru bateriju patēriņa samazināšanai, meža kameras, kuras bija novietotas vietā ar dzīvnieku piesaistītāju, kā sālsstabs vai barotava, kamera aktivizācijā uzņēma 1 attēlu, un laiks līdz nākamajai aktivizācijai bija 15 minūtes.



1 . Attēls. Piemēri no meža kamerām. Alnis mežā dienas laikā (pa kreisi), četri brieži pie sālsstaba nakts laikā (pa labi).

Figure 1. Examples of camera trap images. An elk in the forest during the day (left), and four red deer by a salt stake in the night (right).

Pētījumā tika izmantotas 21 meža kameras, kuru atrašanās vieta varēja mainīties pētījuma laikā. Kopumā šajā laika periodā meža kameras tika izvietotas 32 lokācijās. Meža kameru novietojums tika kategorizēts 7 daļās, trijās no kurām – “Barotava”, “Meža barotava”, un “Sālsstabs”, dzīvnieki tika piesaistīti ar barību vai uzturvielām (2. Attēls), bet pārējās – ‘Mežs’, ‘Meža taka’, ‘Izcirtums’, ‘Ceļš’ dzīvnieki netika piesaistīti. Atsevišķās novietojuma kategorijās dati netika ievākti visu cauru gadu – ‘Mežā’ janvārī un februārī, ‘Meža barotavā’ pēc aprīļa, ‘Izcirtumā’ augustā, septembrī un janvārī. Mežā un izcirtumā sakarā ar datu ievākšanas problēmām, un meža barotavā, jo dzīvnieki pēc tam netika piesaistīti, tādējādi zaudējot šo īpašību. Meža kameras netika izvietotas sistemātiski vai pēc nejaušības principa, lai ievāktu vairāk apmācības datus ar dzīvniekiem tālāka mašīnmācīšanās modeļa attīstīšanai, tādējādi izvēloties vietas, kur ir sagaidāma dzīvnieku aktivitāte.



2. Attēls. Pētījuma teritorija. Katrs punkts atbilst meža kameras lokācijai pētījuma laikā.

Figure 2. Study area. Each point represents a camera trap deployment during the study period.

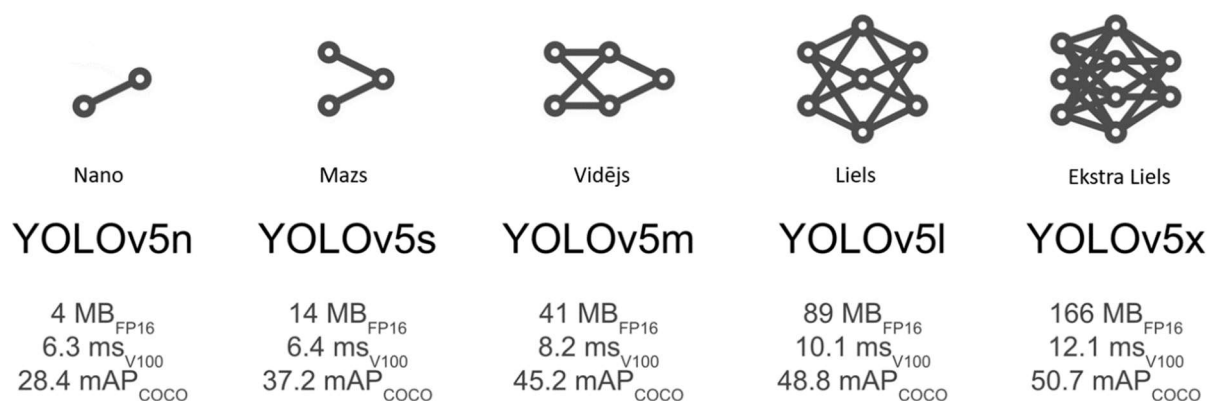
2.3 Datu apstrādes metodes

Meža kameru attēli tika apstrādāti izmantojot divas metodes – ar vizuālo atpazīšanu, un dziļās mašīnmācīšanās modeli. Tika atpazītas četras pārnadžu sugas – staltbriedis, stirna, alnis un meža cūka.

Vizuālā atpazīšana tika veikta, katrā attēlā atzīmējot esošo pārnadžu īpatņu sugu un skaitu. Lai vizuālās novērošanas rezultāti būtu salīdzināmi ar dziļās mašīnmācīšanās datiem, attēlā tika uzskaitīts tikai esošo dzīvnieku daudzums, neņemot vērā iepriekšējo vai nākamo attēlu kontekstu dzīvnieku skaita noteikšanā. Nevienā no attēliem nebija situācija, kurā pārnadža piederība sugai netika noteikta.

Kā mašīnmācīšanās metode tika izmantots YOLOv5 objektu noteikšanas dziļās mašīnmācīšanās modelis (Jocher et al., 2022). Šis modelis ir turpinājums YOLOv3 objektu noteikšanas modelim, kurš sastāv no trīs daļām – mugurkauls, kurā ir konvolūtīvais neironu tīkls, kurš nosaka galvenās pazīmes. Tālāk seko kakls, kas sastāv no vairākiem slāņiem, kuri

savieno galvenās pazīmes un nodod tālāk uz modeļa galvu, kura klasificē mērķa objektus. YOLOv5 modelim, salīdzinot ar iepriekšējo versiju YOLOv4, ir izmainīta mugurkaula daļas struktūra, kas modeli padara mazāku un attēlu klasificēšanu ātrāku. YOLOv5 ir apmācīts un testēts uz COCO datu kopas, kas ir populāra etalona datu kopa mašīnmācīšanās modeļu izveidei (Lin et al., 2014). YOLOv5 ir sadalīts dažādos modeļu veidos atkarībā no lieluma un rezultātu kvalitātes (3. Attēls). Tālākai modeļa apmācīšanai tika izmantots YOLOv5x variants. Modelis tika apmācīts uz attēliem un video no 2020. gadā ievāktiem datiem šajā pašā pētījuma teritorijā ar piecām SnapShot Multi Mobil 3G 16MP HD (Dörr GmbH), un vienu Reconyx HF2X HyperFire 2 meža kameru. Iepriekšējie modeļi tika apmācīti izmantojot lielāku dzīvnieku anotāciju datu bāzi ar vairāk kā 50 000 instancēm (atsevišķi norādīti dzīvnieki attēlā), bet tam tika novērotas ļoti daudz 1. tipa kļūdas. Lai mazinātu šo kļūdu daudzumu, no anotāciju datu bāzes tika izņemti attēli, kuros dzīvnieki ir daļēji vai pilnībā aizklāti ar veģetāciju. Pēdējā modeļa iterācija tika trenēta uz 29 682 paraugiem, no kuriem 564 bija staltbrieži, 13 573 bija stirnas, 1 261 aļņi, un 14 284 meža cūkas. Modelim bija jābūt vismaz 30% pārliecinātam, lai veiktu minējumu par dzīvnieka atpazīšanu.



3. Attēls. Pieejamie YOLOv5 modeļu varianti. YOLOv5n ir mazākais, un YOLOv5x ir lielākais. MB apzīmē modeļa lielumu, ms apzīmē attēlu atpazīšanas ātrumu, un mAP apzīmē modeļa sniegumu.

Figure 3. The available YOLOv5 model variants. YOLOv5n is the smallest and YOLOv5x is the biggest. MB represents model size, ms represents model speed, and mAP represents model performance.

2.4 Statistikas metodes

Vizuālās atpazīšanas datu bāze tika veidota, izmantojot Microsoft® Excel® 2019 MSO izklājlapu. Visa datu apstrāde un statistiskie testi tika veidoti, izmantojot R versiju 4.0.5 un RStudio versijas 1.4.1106 lietotāja saskarni. Katra datu rinda saturēja informāciju par vienu

attēlu - uzņemšanas datumu, īpatņu sugu un skaitu attēlā izmantojot vizuālo atpazīšanu un mašīnmācīšanās modeli, attēla lielumu, nosaukumu, kameru, lokāciju, novietojuma kategoriju u.c. parametrus.

Lai aprēķinātu pārnadžu populācijas relatīvos lielumus pētījuma teritorijā, tika izmantots populācijas relatīvā daudzuma indekss (RDI), kurš tika aprēķināts kā dzīvnieku skaits uz vienu meža kameras dienu (Gilbert et al., 2020). RDI tika izmantots gan sugu savstarpējā īpatsvara noteikšanai, gan kameras novietojuma, mēneša un stundas ietekmes raksturojumam. Lai novērstu viena indivīda atkārtotu uzskaiti, tam atrodoties priekšā kamerai ilgu laika periodu, un palielinātu datu neatkarību, attēli tika sadalīti 'notikumos'. Lai viens notikums tiktu uzskaitīts atsevišķi no iepriekšējā, ir jāpaiet vismaz 30 minūšu intervālam kopš iepriekšējā attēla ja tiek novērota tās pašas sugas indivīds, vai arī jātiek novērotam citas sugas indivīdam (LaFleur & Pebsworth, 2017).

Diennakts laiks tika sadalīts četrās daļās – diena, saulriets, nakts, saullēkts. Saulriets un saullēkts tika aprēķināts kā stundas intervāls pirms un pēc astronomiskā saulrieta un saullēkta (kopā 2 stundas katrs). Diena bija diennakts gaišā daļa, sākot no stundu pēc saullēkta un beidzot ar stundu pirms saulrieta, bet nakts bija diennakts tumšā daļa, sākot no stundu pēc saulrieta un beidzot ar stundu pirms saullēkta.

Lai novērtētu dažādu faktoru ietekmi uz vizuāli atpazīto dzīvnieku skaitu, tika izveidoti un savstarpēji salīdzināti vairāki jaukta efekta vispārinātie lineārie modeļi (GLMM), izmantojot Akaike informācijas kritērijus (AIC), kur zemāks AIC norādīja labāku GLMM veiktspēju. Kā fiksētie parametri modelī tika izmēģināti modeļa atpazītais dzīvnieku daudzums, kameras novietojuma kategorija, mēnesis, diennakts laiks, un kā nejaušais faktors meža kameras lokācija. Dzīvnieku skaita dati atbilda Puasona sadalījumam, tāpēc tika izmantots GLMM ar Puasona kļūdu sadalījumu un logaritmisko saikni. Faktoru ietekme tika uzskatīta par statistiski būtisku pie līmeņa $\alpha = 0.05$.

Mašīnmācīšanās YOLOv5 modeļa salīdzinājumā ar vizuālās atpazīšanas metodi tika pieņemts, ka vizuālās atpazīšanas rezultāti ir 100% pareizi. YOLOv5x modeļa atpazīšanas pareizība tika novērtēta katram no 55 380 attēliem. YOLOv5 RDI salīdzinājumam ar vizuālās atpazīšanas RDI attēli tika sadalīti notikumos, bet pārnadžu sugas netika atsevišķi nodalītas. Lai novērtētu, cik lielu daļu datu variācijas vizuāli atpazīto dzīvnieku skaitā attēlos izskaidro YOLOv5, tika veidots GLMM, kurā vizuāli atpazīto dzīvnieku skaits bija atkarīgais mainīgais (regresents), bet modeļa rezultāts – neatkarīgais mainīgais (regresors). Papildus šim modelim tika novērtēta arī novietojuma kategorija, mēnesis, diennakts laiks, un kā nejaušais faktors arī tika norādītas meža kameras lokācijas.

3 Rezultāti

Laika posmā no 2021. gada 1. decembrim līdz 2022. gada 1. janvārim, kas kopā ilga 6297 kameras dienas, tika analizēti 53 380 attēli, no kuriem 18 341 (34,4%) saturēja vismaz vienu dzīvnieku. No šiem 18 341 attēliem, 14 121 (77,0%) saturēja vismaz vienu staltbriedi, 1 727 (9,4%) stirnu, 1 405 (7,7%) alni, 1 187 (6,5%) meža cūku. Atsevišķi saskaitītais dzīvnieku skaits ir lielāks par kopējo attēlu skaitu ar dzīvniekiem, jo 9 attēli saturēja vairāk par vienu sugu. Attēlos kopā tika uzskaitīti 33 677 dzīvnieki (1. Tabula).

1. Tabula.

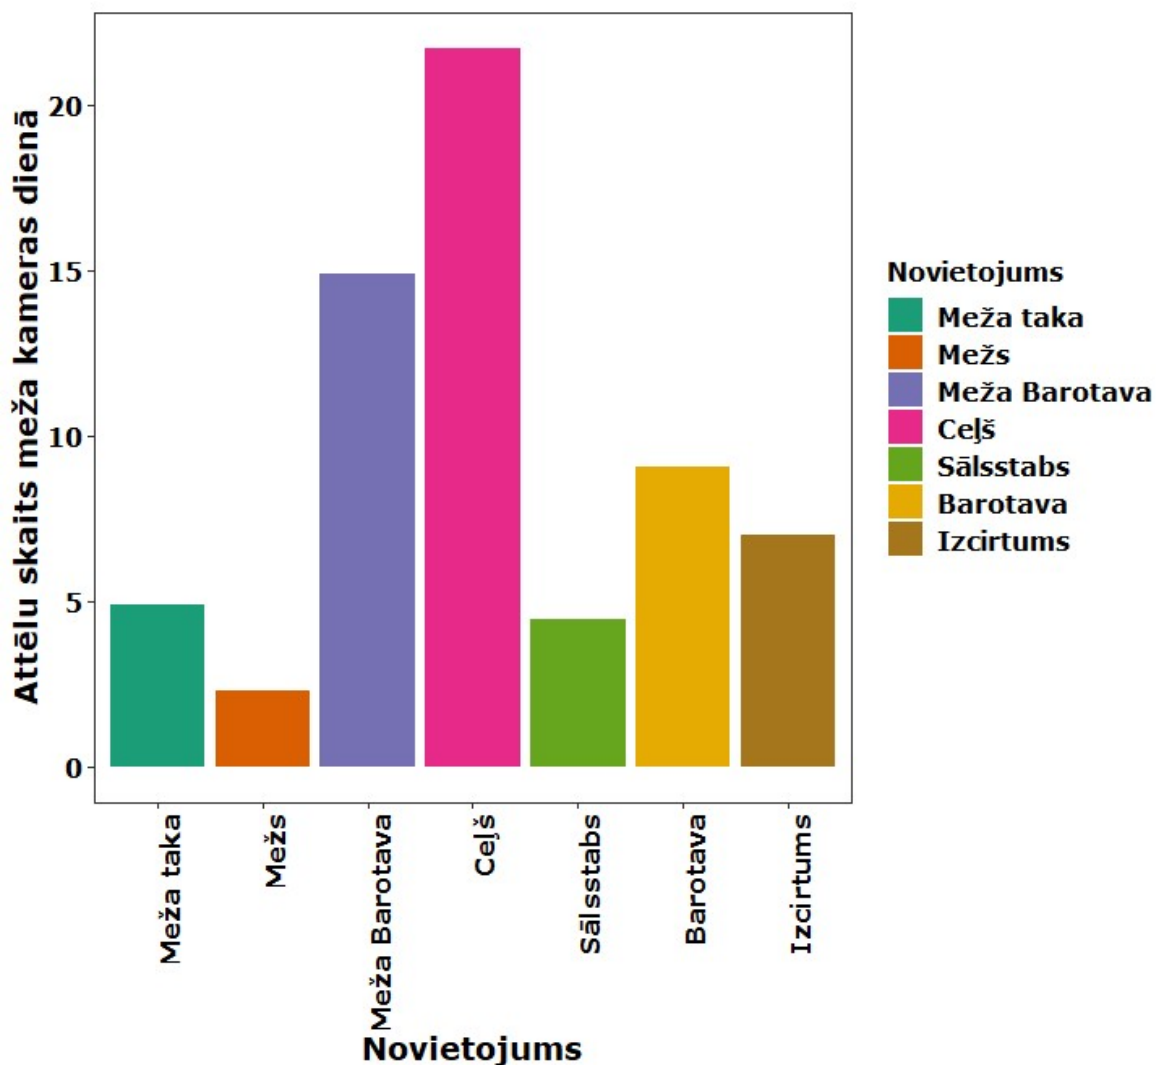
Kopējais dzīvnieku skaits attēlos un notikumos, un kā sadalīšana notikumos ietekmēja uzskaitīto dzīvnieku skaitu atkarībā no sugas.

Table 1

Total number of animals counted in all images and events. The percent reduction column shows how reclassifying images to events effects different species.

	Dzīvnieku skaits attēlos	Dzīvnieku skaits notikumos	Samazinājums, %
Staltbriedis	26 065	5 299	79.7
Stirna	1 934	442	77.1
Alnis	1 593	583	63.4
Meža cūka	4 085	2 031	50.3
Kopā	33 677	8 355	75.2

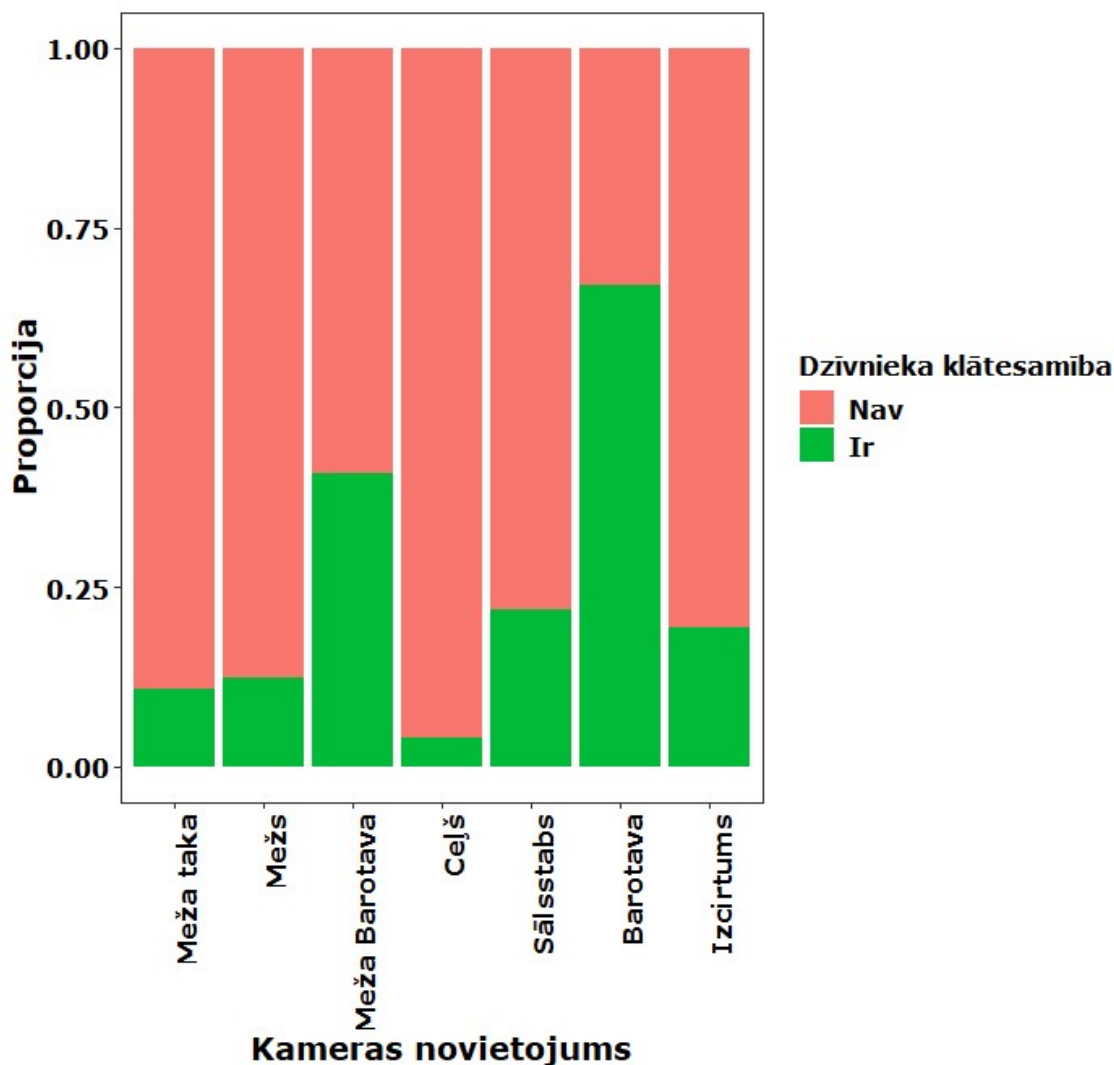
No visiem attēliem tika iegūti 10 238 dažādi notikumi, kuros 4 178 (40,8%) bija vismaz viens dzīvnieks, no kuriem 2 813 (67%) saturēja staltbriedi, 397 (9,5%) stirnu, 515 (12,3%) alni, un 492 (11,8%) meža cūku. Visos notikumos uzskaitīto dzīvnieku skaits bija 8 355 (1. Tabula). Lielākā ietekme attēlu sadalīšanai notikumos bija staltbriedim, un vismazākā meža cūkai.



4. Attēls. Attēlu skaits meža kameras vienā dienā atkarībā no novietojuma.

Figure 4. Number of images per camera trap day in each viewshed category.

Meža kameru attēlu skaits bija atšķirīgs starp novietojumiem (4. Attēls). Vidējais attēlu skaits meža kameras dienā bija 9.19. Viszemākais attēlu skaits uz meža kameras dienu bija meža kategorijā ar 2.29, un vislielākais bija pie ceļa novietotajās kamerās ar 21.7. Katrā no novietojumiem arī atšķīrās tukšo attēlu proporcijas (5. Attēls), kur proporcionāli visvairāk tukšo kadru bija pie ceļa, un vismazāk pie barotavas.




5. Attēls. Proporcionālais attēlu daudzums ar un bez dzīvniekiem, atkarībā no novietojuma.

Figure 5. Proportional number of images with animals and empty images in each viewshed category

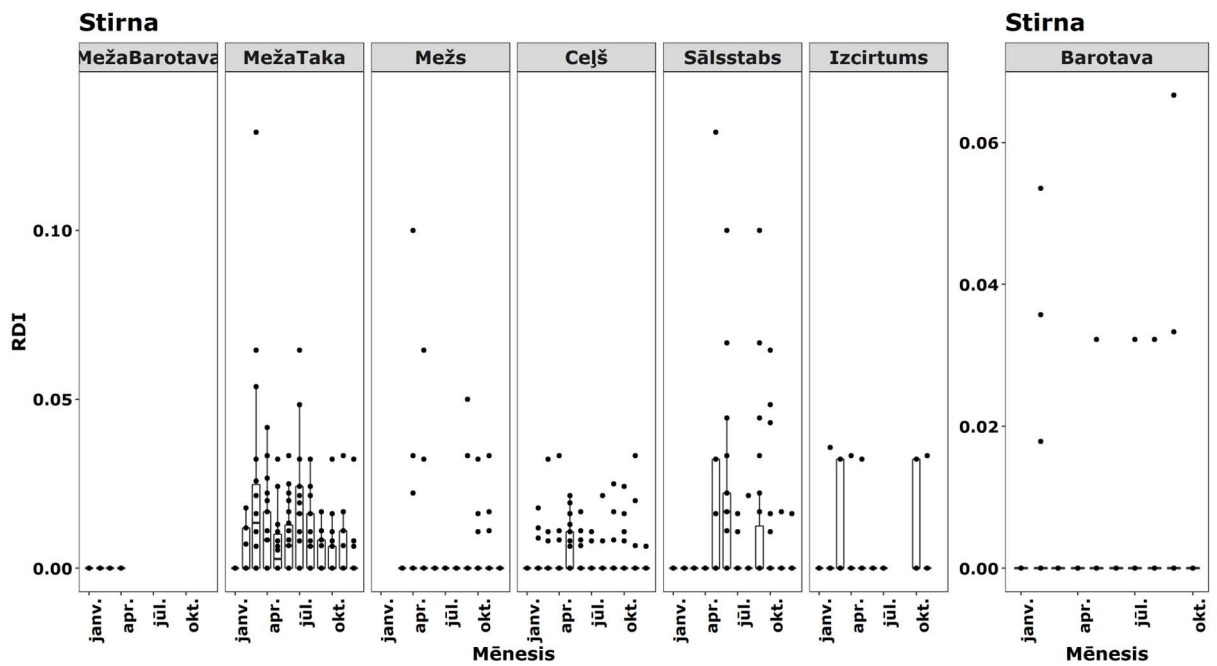
Dzīvnieku skaits notikumos tika pārrēķināts uz RDI, un katrai sugai tika atspoguļots divos griezumos – kalendāro mēnešu (Attēls 6, 7, 8 un 9) un diennakts perioda (Attēls 10, 11, 12, 13). Vislielākais RDI atkarībā no novietojuma gada griezumā staltbriedim un meža cūkai bija barotavā, staltbriedis sasniedza 27.8 RDI janvārī, un meža cūka 13.3 maijā. Staltbriedim barotavā visaugstākais RDI bija janvārī un kritās līdz jūnijam, kad sasniedza 0.17, bet jūlijā un augustā atkal uzkāpa līdz 1.74 un 2.94. Meža cūkām RDI bija augsts visu pavasari, kad tas sasniedza augstāko RDI maijā (13.3). Stirna un Alnis barotavas apmeklēja pārāk reti, lai spētu

veidot analīzi. Meža barotavu apmeklēja, galvenokārt, staltbriedis ziemas periodā, un alnis janvārī. Tā kā staltbriedim bija visvairāk novērojumu, tam var vislabāk noteikt mēnešu un diennakts uzvedības maiņas novērojumu kategorijās. Staltbriedim meža takā visaugstākais RDI bija janvārī, mežā tas bija vienmērīgs visu cauru gadu. Uz ceļa staltbriedim augstākais RDI tam bija pavasara un vasaras mēnešos. Staltbriedim diennakts aktivitāte visaugstākā bija saullēktā un saulrietā, izņemot barotavā kurā vislielākais RDI bija naktī. Alnim lielākā aktivitāte bija pie sālsstaba naktī, meža cūkām barotavās naktī.




6. Attēls. Staltbrieža RDI 2021. gadā atkarībā no novietojuma.

Figure 6. RDI of red deer in 2021 by camera trap viewshed.




7. Attēls. Stirnas RDI 2021. gadā atkarībā no novietojuma.

Figure 7. RDI of roe deer in 2021 by camera trap viewshed.



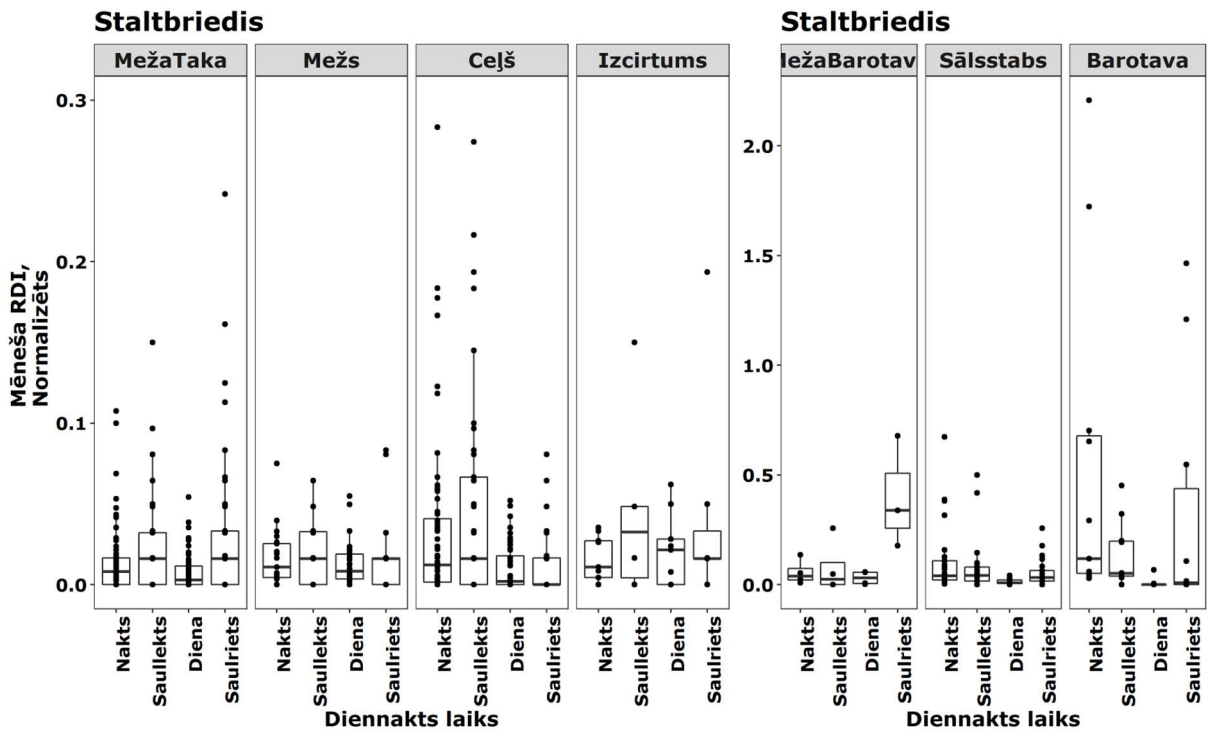
8. Attēls. Aļņa RDI 2021. gadā atkarībā no novietojuma.

Figure 8. RDI of elk in 2021 by camera trap viewshed.



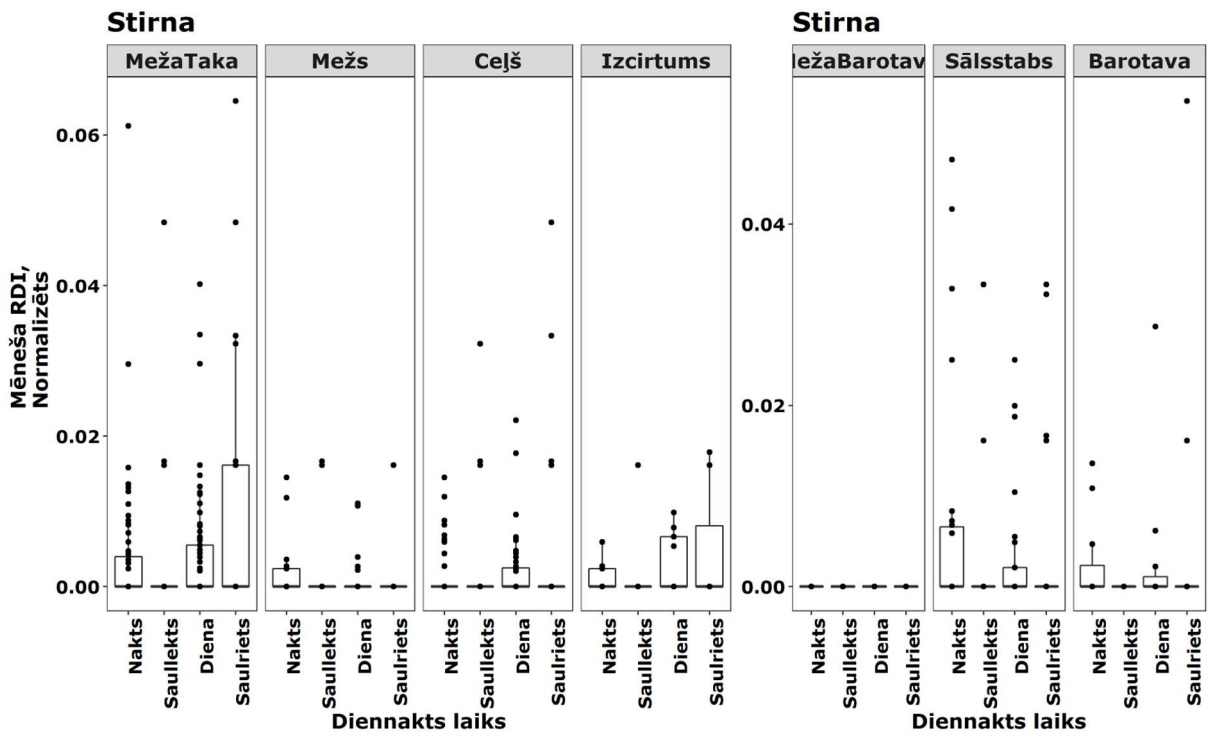
9. Attēls. Meža cūka RDI 2021. gadā atkarībā no novietojuma.

Figure 9. RDI of wild boar in 2021 by camera trap viewshed.



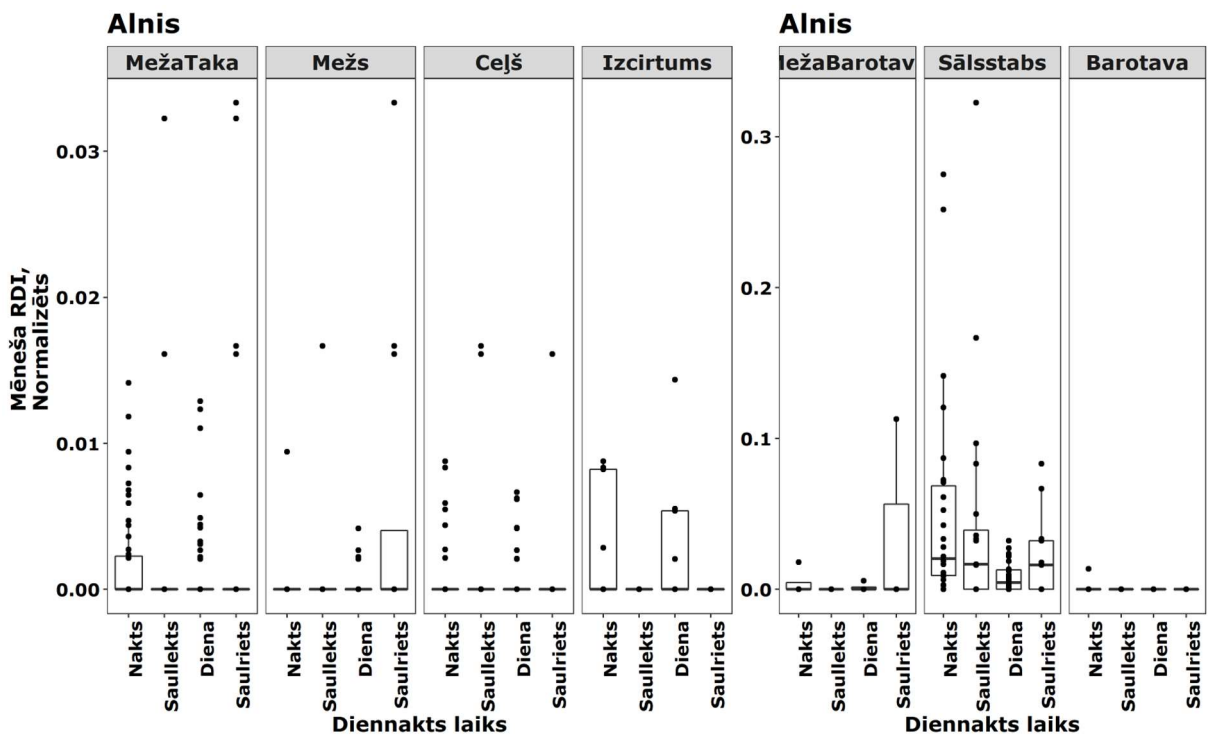
10. Attēls. Staltbrieža RDI atkarībā no diennakts laika un novietojuma.

Figure 10. RDI of red deer by time of day and camera trap viewshed.



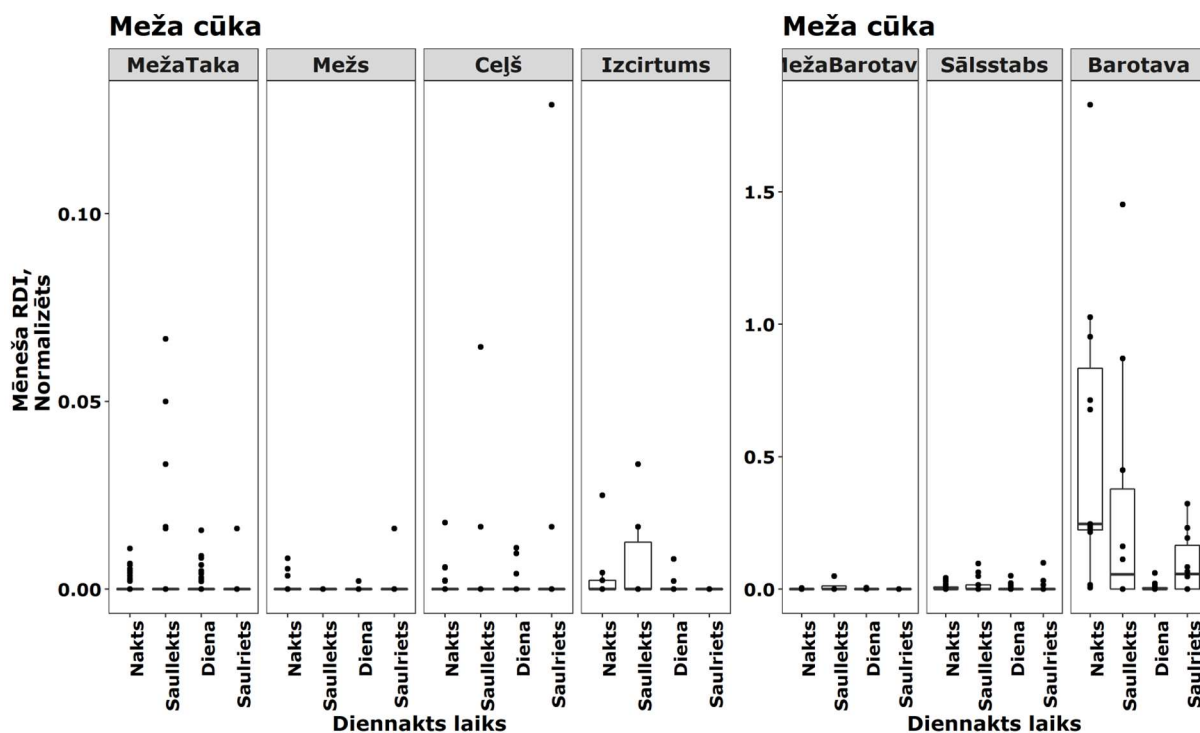
11. Attēls. Stirnas RDI atkarībā no diennakts laika un novietojuma.

Figure 11. RDI of roe deer by time of day and camera trap viewshed.



12. Attēls. Aļņa RDI atkarībā no diennakts laika un novietojuma.

Figure 12. RDI of elk by time of day and camera trap viewshed.



13. Attēls. Meža cūkas RDI atkarībā no diennakts laika un novietojuma.

Figure 13. RDI of wild boar by time of day and camera trap viewshed.

Tika izmēģināti 15 dažādi GLMM, kuros attēlos vizuāli atpazīto dzīvnieku skaits tika skaidrots ar dažādām pieejamo ietekmējošo faktoru kombinācijām modeļa formulā. No tiem konverģējās 10 modeļi (2 tabula), no kuriem labākais bija modelis, kurā dzīvnieku skaitu izskaidroja ar kameras novietojumu, diennakts laiku un abu šo faktoru mijiedarbību. Šis modelis spēja izskaidrot 69,6% datu variācijas (pseido R^2). Modeļa brīvais loceklis (intercept) ar ko tika salīdzinātas pārējās faktoru kombinācijas, bija meža taka naktī. Saskaņā ar šo modeli dienā uz meža takas tika reģistrēti būtiski mazāk dzīvnieku nekā pārējos diennakts periodos, kā arī būtiski mazāk dzīvnieku naktī tika konstatēti izcirtumā un uz ceļa. Dienas laikā mazāk dzīvnieku tika reģistrēti barotavā, meža barotavā, uz ceļa nekā uz meža takas, bet vairāk - izcirtumā, saulrieta laikā uz ceļa un barotavā, bet saullēkta laikā - barotavā (3. tabula).

2. Tabula.

Modeļu savstarpējais salīdzinājums dzīvnieku skaitam ar vizuālās atpazīšanas metodi un ietekmējošiem faktoriem. Modelis 9 raksturoja dzīvnieku skaitu vislabāk. Sarežģītāki

modeļi

Table 2.

Comparison between models between animal count using visual observation and impacting factors. Model 9 explained animal count the best.

Modeļa nr	Komponentes	AIC	Δ AIC
9	Vizuālās atpazīšanas ~ novietojums * diennakts laiks	19364	0
8	Vizuālās atpazīšanas ~ mēnesis * diennakts laiks	19735	371
7	Vizuālās atpazīšanas ~ mēnesis + novietojums + diennakts laiks	20024	660
5	Vizuālās atpazīšanas ~ mēnesis + diennakts laiks	20040	676
4	Vizuālās atpazīšanas ~ novietojums + diennakts laiks	20194	830
3	Vizuālās atpazīšanas ~ diennakts laiks	20205	841
10	Vizuālās atpazīšanas ~ novietojums * mēnesis	20402	1038
6	Vizuālās atpazīšanas ~ mēnesis + novietojums	21229	1865
2	Vizuālās atpazīšanas ~ mēnesis	21254	1890
1	Vizuālās atpazīšanas ~ novietojums	21367	2003

3. Tabula.


Modeļa 9 rezultāti. 'TimeOfDay' apzīmē diennakts laiku, un 'description' apzīmē kameras novietojumu.

Table 3.

Results of model 9. 'TimeOfDay' represents the time of day, and 'description' represents camera viewshed category.

	Novērtējums	Std. Kļūda.	Z vērtība	Pr(> z)	
(Intercept)	-0.36881	0.178	-2.063	0.0391	*
TimeOfDaySaullekts	0.14788	0.107	1.373	0.1697	
TimeOfDayDiena	-0.32903	0.077	-4.227	< 0.0001	***
TimeOfDaySaulriets	0.10563	0.103	1.018	0.3088	
descriptionMežs	0.17342	0.379	0.457	0.6474	
descriptionMežaBarotava	0.90713	0.665	1.362	0.1730	
descriptionCeļš	-0.67209	0.294	-2.285	0.0223	*
descriptionSālsstabs	0.61426	0.409	1.502	0.1331	
descriptionBarotava	0.84245	0.489	1.720	0.0855	.
descriptionIzcirtums	-0.61694	0.181	-3.399	0.0006	***
TimeOfDaySaullekts:descriptionMežs	-0.41205	0.241	-1.705	0.0882	.
TimeOfDayDiena:descriptionMežs	0.15979	0.156	1.018	0.3085	
TimeOfDaySaulriets:descriptionMežs	-0.15139	0.240	-0.629	0.5290	
TimeOfDaySaullekts:descriptionMežaBarotava	-0.30547	0.260	-1.172	0.2411	
TimeOfDayDiena:descriptionMežaBarotava	-0.99021	0.229	-4.315	< 0.0001	***
TimeOfDaySaulriets:descriptionMežaBarotava	0.33030	0.186	1.773	0.0761	.
TimeOfDaySaullekts:descriptionCeļš	0.11974	0.136	0.880	0.3789	
TimeOfDayDiena:descriptionCeļš	-1.29704	0.110	-11.704	< 0.0001	***
TimeOfDaySaulriets:descriptionCeļš	-1.28100	0.168	-7.624	< 0.0001	***
TimeOfDaySaullekts:descriptionSālsstabs	-0.18441	0.132	-1.393	0.1635	
TimeOfDayDiena:descriptionSālsstabs	0.18653	0.104	1.779	0.0752	.
TimeOfDaySaulriets:descriptionSālsstabs	-0.18956	0.141	-1.343	0.1793	
TimeOfDaySaullekts:descriptionBarotava	-0.44415	0.124	-3.562	0.0003	***
TimeOfDayDiena:descriptionBarotava	-2.36240	0.145	-16.281	< 0.0001	***
TimeOfDaySaulriets:descriptionBarotava	-0.39788	0.122	-3.257	0.0011	**
TimeOfDaySaullekts:descriptionIzcirtums	-0.00895	0.281	-0.032	0.9746	
TimeOfDayDiena:descriptionIzcirtums	0.80537	0.187	4.292	< 0.0001	***
TimeOfDaySaulriets:descriptionIzcirtums	0.22128	0.278	0.796	0.4261	

‘.’ – $p = 0.05 - 0.10$, * - $p < 0.05$, ** - $p < 0.001$, *** - $p < 0.0001$



14. Attēls. Izskaidrotā dzīvnieku skaita atkarība no diennakts laika un novietojuma saskaņā ar labāko GLMM, kas izskaidro vizuāli atpazīto dzīvnieku skaitu meža kamerās. Y ass ir ierobežota līdz 3, lai variācija būtu saskatāmāka visās klasēs.

Figure 14. Explained animal count by time of day and viewshed category by the GLMM model that described animal visual observation counts in camera traps the best. The Y-axis is limited to 3 to see the variation in all categories more clearly.

Pārnadžu populāciju vērtējums pētījuma teritorijā atšķīrās starp dažādām uzskaites metodēm (4. tabula). Visas metodes, izņemot RDI, ir absolūtie populācijas blīvuma vai lieluma novērtējumi, tāpēc salīdzinājumam izmantots savstarpējais sugu proporcionālais novērtējums. Meža kameru RDI novērtēja līdzīgu populāciju īpatsvaru staltbriedim kā ekskrementu uzskaites (-0,1%) un bezpilota lidaparāta pārlidojums (+ 4,3%), bet lielāku īpatsvaru nekā Valsts Meža Dienesta (+ 47,9%) un mežziņa (+ 36,1%) novērtējumi. RDI novērtējums sniedza līdzīgu stirnu īpatsvaru kā bezpilota lidaparāta pārlidojums (- 2%), lielāku nekā ekskrementu uzskaites (+ 7,6%), un mazāku nekā VMD (- 30,7%) un mežziņa (- 30,8%) novērtējumu. RDI noteica zemāku aļņu īpatsvaru nekā visas pārējās metodes.

4. Tabula.

Dažādu pārnadžu uzskaišu metožu sniegto populācijas novērtējumu salīdzinājums pētāmajā teritorijā. Pēdējais Silavas populācijas novērtējums ar ekskrementu uzskaiti tika veikts gadu iepriekš. Meža cūku īpatsvars netika salīdzināts, jo to populāciju novērtēja tikai VMD.

Table 4.

Comparison between different ungulate population estimate methods in the pilot territory. The last pellet count by Silava was made the year prior.

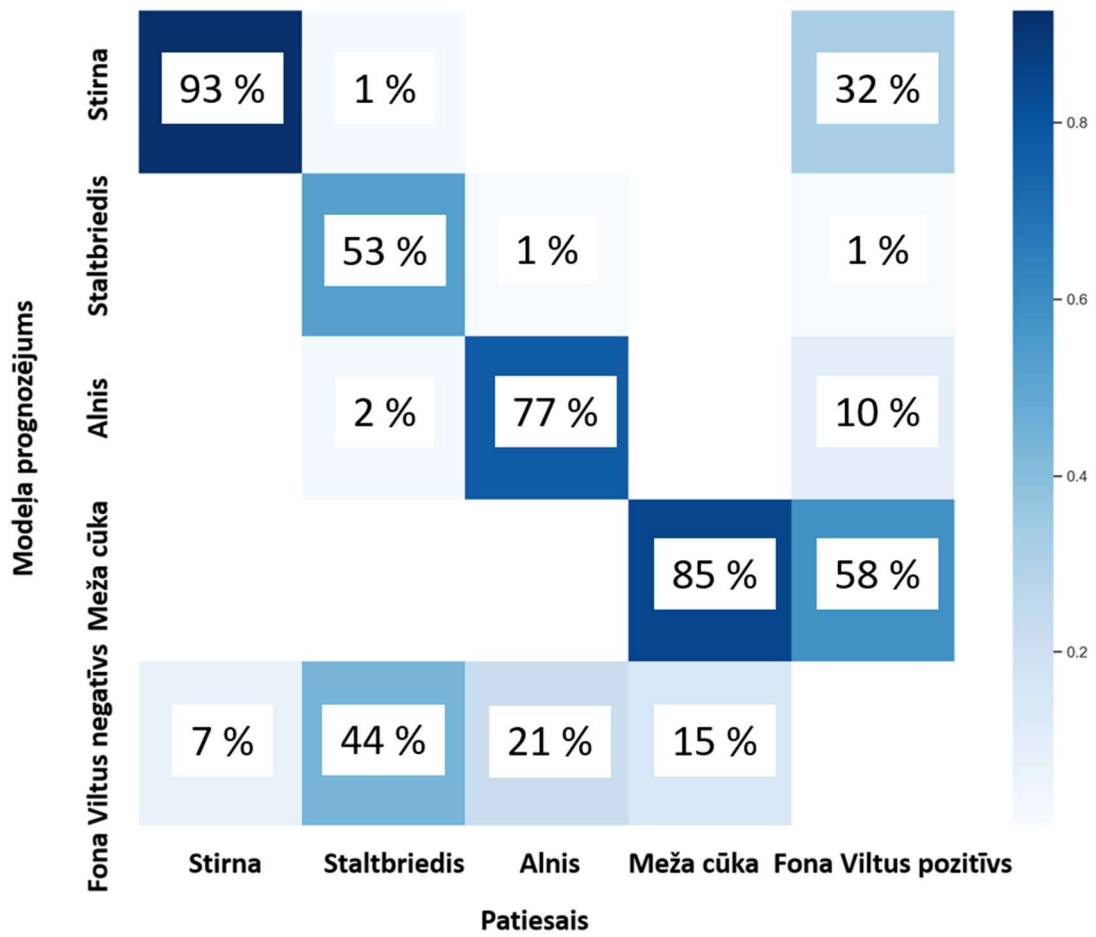
	Meža kameras RDI* oktobris – decembris 2021	Silavas ekskrementu uzskaites oktobris-decembris 2020	Dzīvnieki uz 1000 ha Latvijas Valsts Meža dienests 2021	Vietējā mežziņa minējums 2021	Bezpilot lidaparāta pārlidojumi decembris 2021
Staltbriedis	51.5 (87,3%)	86.94 (87,4%)	32.6 (39,4%)	65 (60-70) (51,2%)	52.4 (79%)
Stirna	5.06 (8,6%)	1 (1%)	39.3 (47,5%)	50 (40-60) (39,4%)	7 (10,6%)
Alnis	2.46 (4,1%)	11,57 (11,6%)	10.9 (13%)	12 (9,4%)	6.9 (10,4%)
Meža cūka	2,88 (Neuzskaitīti)	-	9,2 (Neuzskaitīti)	-	-

*Meža kameru RDI ir aprēķināts kā dzīvnieku skaits uz 100 meža kameras naktīm.

*RDI is calculated as the total amount of animals per 100 camera trap nights


YOLOv5 modeļa performance ir pārbaudīja ar divām datu kopām – uz validācijas datu kopu, kas izmantota modeļa apmācībā, un pēc tam uz visiem 55 380 attēliem no 2021. gada pētījuma, kurus modelis pirms tam nebija redzējis. Modeļa apmācīšana aizņēma 16 stundas, un vienas bildes klasificēšana modelim aizņēma no 0.1 līdz 0.3 sekundēm.

Attēlā 15 ir redzama pārpratumu matrica, izmantojot apmacības-testa datu kopas. Vislabākie modeļa rezultāti bija stirnām, kurām tas pareizi klasificēja 93% gadījumu, un vissliktākie rezultāti bija staltbriedim, kurus pareizi klasificēja tikai 53% no instancēm. Neviena pārnadžu suga netika savā starpā nepareizi klasificēta vairāk par 2% gadījumu, kas norāda ka lielākā daļa nepareizu klasificētu instanču bija 2. tipa kļūdas. No 1. tipa kļūdām uz fona visvairāk bija mežacūkām (58%) un stirnām (53%), un vismazāk staltbriedim (1%). Precizitātes-Atdeves līkne 16. Attēlā norāda uz modeļa veiktspēju katrai pārnadžu sugai. Modeļa F1 rādītājs ir 80%.



15. Attēls. Modeļa pārpratumu matrica uz apmācības-testa datu kopas.

Figure 15. Confusion matrix of the training-test data set.



16. Attēls. Precizitātes-Atdeves līkne uz apmācības-testa kopas datiem. Augstāks rezultāts norāda uz labāku modeļa veiktspēju.

Figure 16. Precision-Recall curve for the training and test set. Higher results for each species correspond to better performance.

Tabulā 5 redzama modeļa pārpratumu matrica vispārējā dzīvnieku atpazīšanā, kurā netika ņemts vērā vai noteiktā suga ir klasificēti pareizi. No 55 380 attēliem, tas pareizi noteica dzīvnieka esamību 11 464 no 18 341 attēliem (62,5%), un pareizi noteica dzīvnieku neesamību attēlā 33 303 no 35 039 attēliem (95%). Kopējā modeļa pareizība dzīvnieku atpazīšanā ir 83,9%.

5. Tabula.

Detekcijas pārpratumu matrica 53 380 pētījuma attēliem attēliem, kuri tika testēti uz YOLOv5 modeļa. Patiesi pozitīvi tiek uzskaitīti, kad vismaz viens dzīvnieks ir ticis detektēts attēlā ar dzīvnieku.

Table 5.

Confusion matrix of all 55 380 study images on the YOLOv5 model. A true positive is counted when the model detects the presence of at least 1 animal in an image.

Patiesi pozitīvi 11 464 62,5%	Viltus pozitīvi 1 736 5. 0%
Viltus negatīvi 6 877 37,5%	Patiesi negatīvi 33 303 95,0%

Modeļa klasifikācija 6. Tabulā uz iepriekš neredzētiem pētījuma datiem uzrāda sliktākus rezultātus kā 15 attēlā. Kā dzīvnieki detektēti mazāk nekā puse no visām stirnām, pārējās sugas no 63,9% - 65,7%. Vislabākie YOLOv5 klasifikācijas rezultāti bija stirnām, tika pareizi klasificētas tika 763 no detektētajām 777 stirnām (98,2%), un 543 no detektētajām 766 meža cūkām (70,9%).

6. Tabula.


Modeļa pārpratuma matrica pārnadžu sugu klasificēšanai.

Table 6.

Confusion matrix of the model for each species classification.

Dzīvnieks	Attēlu skaits ar dzīvnieku	Detektēts kā dzīvnieks	Pareizi klasificēta suga	Pareizi klasificēta suga + skaits
Staltbriedis	14 211 100%	9 080 63,9%	13 0,1%	8 0,1%
Stirna	1 728 100%	777 45,0%	763 44,2%	684 39,6%
Alnis	1 405 100%	923 65,7%	0	0
Meža cūka	1 187 100%	766 64,5%	543 45,7%	139 11,7%

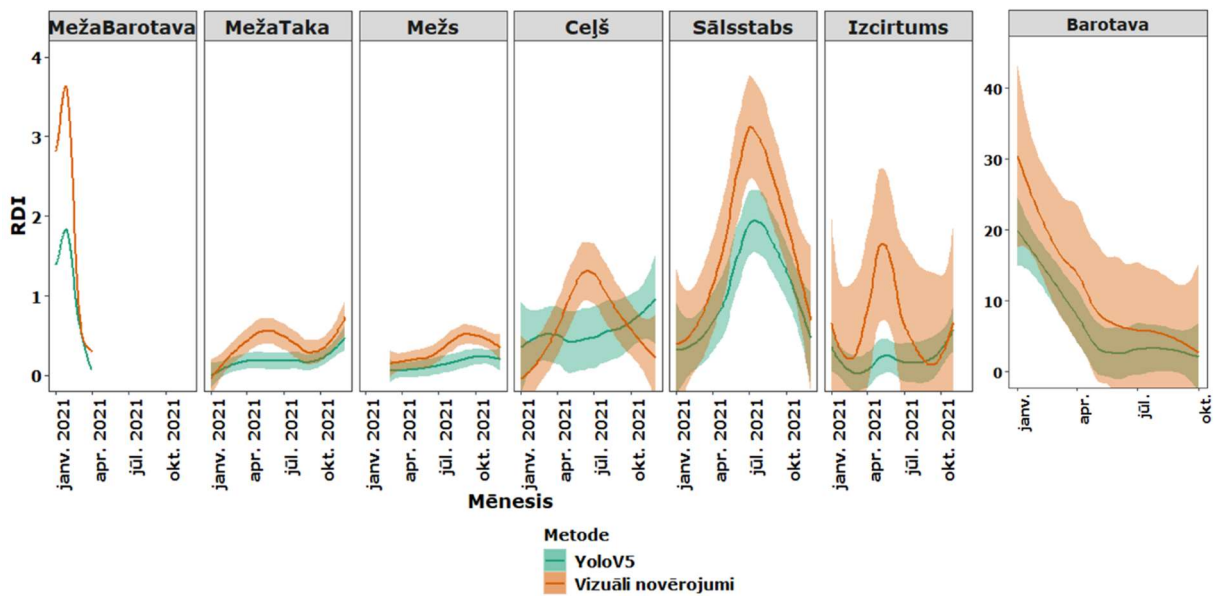
Modeļa pareizība nebija vienāda visos novietojumos (17. Attēls). Viszemākā tā bija izcirtumā un mežā (62% un 64%), un visaugstākā pie barotavas un ceļa (88% un 83%).



17. Attēls. Pareizi atpazīto dzīvnieku daudzums atkarībā no novietojuma.

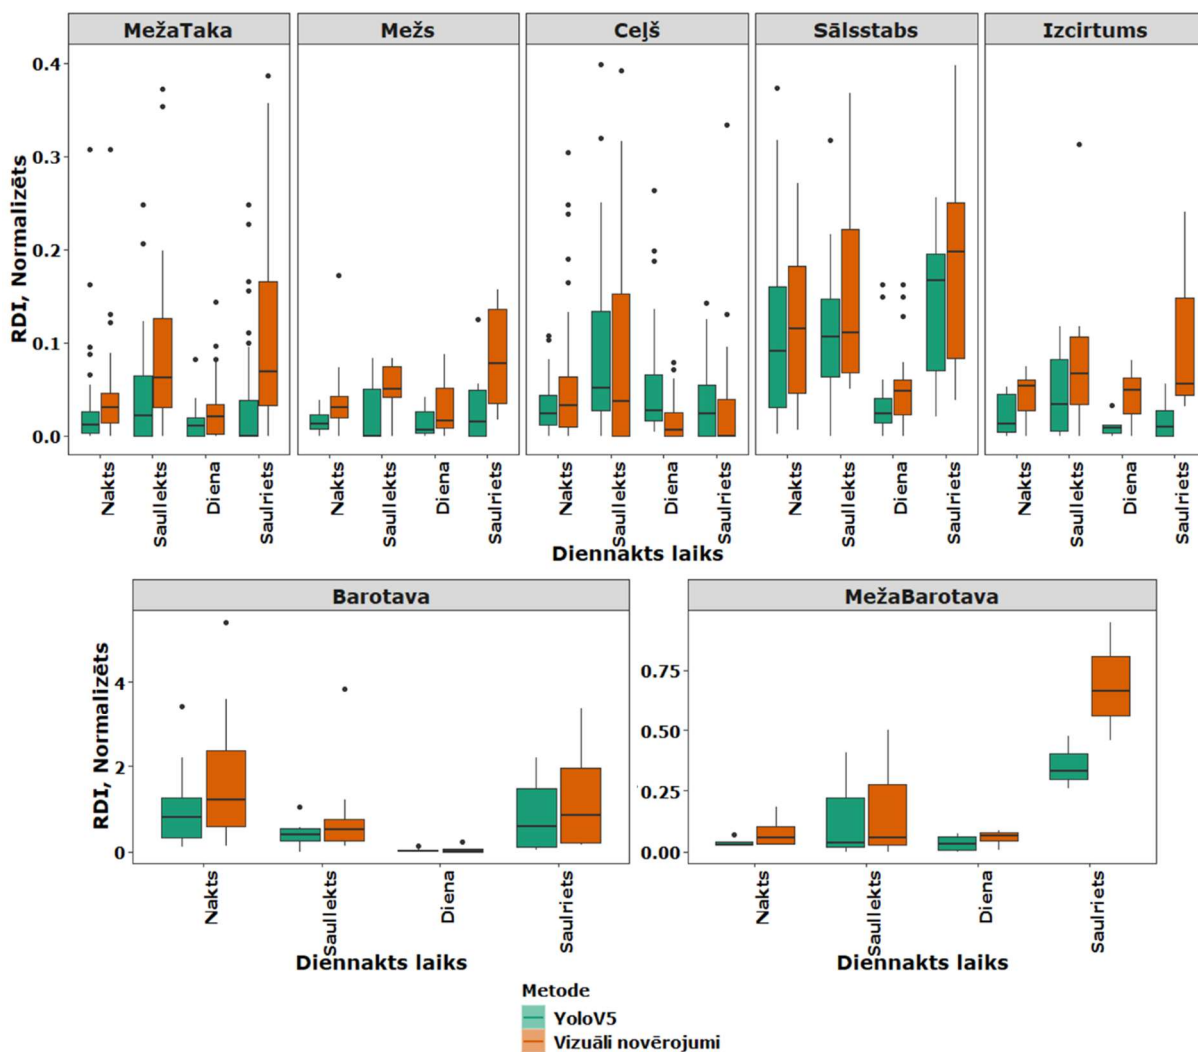
Figure 17. Detection accuracy by viewshed category.

18. un 19. Attēlā ir redzams YOLOv5 modeļa salīdzinājums ar vizuālās atpazīšanas metodi. YOLOv5 RDI novērtējums parasti ir zemāks par vizuālo novērojumu metodi, bet tam ir augstāks RDI novietojumā pie ceļa ziemas mēnešos un dienas gaišajā laikā, kas norāda uz iespējamām viltus pozitīvā kļūdām.



18. Attēls. Vizuālās atpazīšanas mašīnmācīšanās modeļa RDI salīdzinājums atkarībā no gada mēneša un meža kameras novietojuma..

Figure 18. Comparison between visual observations and machine learning model results by month and viewshed category.



19. Attēls. Vizuālās atpazīšanas un mašīnmācīšanās modeļa RDI salīdzinājums atkarībā no diennakts laika un meža kameras novietojuma.

Figure 19. Comparison between visual observations and machine learning model results by hour and viewshed category.

GLMM, kurā attēlos vizuāli atpazīto dzīvnieku skaits tika izskaidrots ar YOLOv5 modeļa atpazīto dzīvnieku skaitu, spēja izskaidrot 51,1% no variācijas (7. Tabula).

7. Tabula. Vizuālās novērošanas skaita izskaidrojums ar YOLOv5 modeli.

Table 7. Estimating visual observation count from YOLOv5 model counts.

	Novērtējums	Std. Kļūda	Z vērtība	Pr(> z)	Būtiskums
(Intercept)	-0.836249	0.152397	-5.487	4.08e-08	***
YOLOv5 skaits	0.334857	0.006149	54.454	< 0.0001	***

Papildus tika izmēģināti vēl 15 dažādi GLMM, kuros attēlos vizuāli atpazīto dzīvnieku skaits tika skaidrots gan ar YOLOv5 modeļa skaitu, gan dažādām pieejamo ietekmējošo faktoru kombinācijām modeļa formulā. No tiem konverģējās 9 modeļi (8. Tabula), no kuriem labākais bija modelis, kurā vizuāli atpazīto dzīvnieku skaitu izskaidroja ar YOLOv5 modeļa atpazīto dzīvnieku skaitu, kameras novietojumu, diennakts laiku un abu pēdējo faktoru mijiedarbību. Šis modelis spēja izskaidrot 69,7% datu variācijas (pseido R^2). Modeļa brīvais loceklis (intercept), ar ko tika salīdzinātas pārējās faktoru kombinācijas, bija meža taka naktī. Saskaņā ar šo modeli, YOLOv5 modeļa atpazīto dzīvnieku skaits būtiski izskaidroja vizuālo novērojumu skaitu. Dienā uz meža takas tika reģistrēti būtiski mazāk dzīvnieku nekā pārējos diennakts periodos, kā arī būtiski mazāk dzīvnieku naktī tika konstatēti izcirtumā un uz ceļa. Dienas laikā mazāk dzīvnieku tika reģistrēti barotavā, meža barotavā, uz ceļa, pie sālsta nekā uz meža takas, bet vairāk - izcirtumā, saulrieta laikā uz ceļa un barotavā, bet saullēkta laikā - barotavā (9. Tabula) nekā uz meža takas naktī.

8. Tabula

Modeļu savstarpējais salīdzinājums dzīvnieku skaitam ar vizuālo atpazīšanu un skaitam no mašīnmācīšanās modeļa, un ietekmējošiem faktoriem. Modelis 9 raksturoja dzīvnieku skaitu vislabāk

Table 8.

Comparison between models between animal count using visual observations and machine learning model and impacting factors. Model 9 explained animal count the best.

Modeļa nr	Formula	AIC	Δ AIC
9	Vizuālās atpazīšanas skaits \sim YOLOv5 skaits + novietojums * diennakts laiks	17630	0,00
8	Vizuālās atpazīšanas skaits \sim YOLOv5 skaits + mēnesis * diennakts laiks	17723	93
7	Vizuālās atpazīšanas skaits \sim YOLOv5 skaits + mēnesis + novietojums + diennakts laiks	17828	198
5	Vizuālās atpazīšanas skaits \sim YOLOv5 skaits + mēnesis + diennakts laiks	17845	215
4	Vizuālās atpazīšanas skaits \sim YOLOv5 skaits + novietojums + diennakts laiks	18137	507
3	Vizuālās atpazīšanas skaits \sim YOLOv5 skaits + diennakts laiks	18150	520
6	Vizuālās atpazīšanas skaits \sim YOLOv5 skaits + mēnesis + novietojums	18429	799
2	Vizuālās atpazīšanas skaits \sim YOLOv5 skaits + mēnesis	18451	821
1	Vizuālās atpazīšanas skaits \sim YOLOv5 skaits + novietojums	18691	1061
10	Vizuālās atpazīšanas skaits \sim YOLOv5 skaits	18707	1077

9. Tabula.

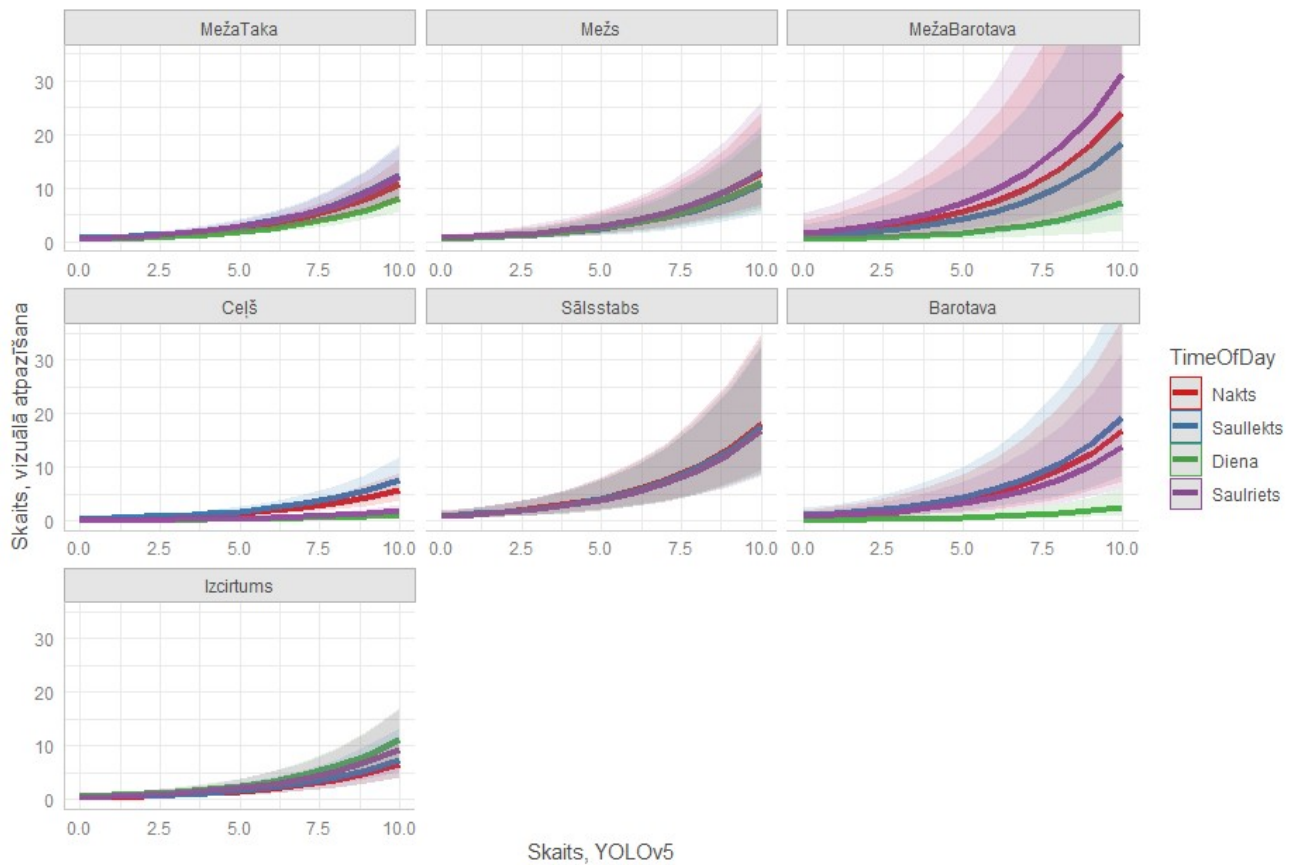
Modeļa 9 rezultāti vizuālā skaita izskaidrojumam ar YOLOv5 modeļa skaitu un dažādiem faktoriem. 'TimeOfDay' apzīmē diennakts laiku, un 'description' apzīmē kameras novietojumu.

Table 9.

Results of model 9 for estimating visual observation counts from YOLOv5 model counts and different factors. 'TimeOfDay' represents the time of day, and 'description' represents camera viewshed category.

	Novērtējums	Std. Kļūda	z vērtība	Pr(> z)	
(Intercept)	-0.518078	0.1619	-3.200	0.0013	**
YOLOv5 skaits	0.290451	0.0066	43.371	< 0.0001	***
TimeOfDaySaullekts	0.142592	0.1077	1.323	0.18577	
TimeOfDayDiena	-0.293421	0.0776	-3.779	0.00015	***
TimeOfDaySaulriets	0.119957	0.1039	1.154	0.24867	
descriptionMežs	0.182666	0.3437	0.531	0.59513	
descriptionMežaBarotava	0.797426	0.5978	1.334	0.18227	
descriptionCeļš	-0.625773	0.2658	-2.354	0.01858	*
descriptionSālsstabs	0.509806	0.3660	1.393	0.16370	
descriptionBarotava	0.433931	0.4399	0.986	0.32400	
descriptionIzcirtums	-0.503064	0.1816	-2.769	0.00562	**
TimeOfDaySaullekts:descriptionMežs	-0.328620	0.2417	-1.359	0.17404	
TimeOfDayDiena:descriptionMežs	0.132115	0.1566	0.844	0.39886	
TimeOfDaySaulriets:descriptionMežs	-0.116106	0.2412	-0.481	0.63025	
TimeOfDaySaullekts:descriptionMežaBarotava	-0.419080	0.2606	-1.608	0.10793	
TimeOfDayDiena:descriptionMežaBarotava	-0.887886	0.2294	-3.870	0.00010	***
TimeOfDaySaulriets:descriptionMežaBarotava	0.136096	0.1864	0.730	0.46543	
TimeOfDaySaullekts:descriptionCeļš	0.124651	0.1361	0.915	0.36004	
TimeOfDayDiena:descriptionCeļš	-1.270715	0.1106	-11.486	< 0.0001	***
TimeOfDaySaulriets:descriptionCeļš	-1.225355	0.1681	-7.286	< 0.0001	***
TimeOfDaySaullekts:descriptionSālsstabs	-0.177000	0.1324	-1.337	0.1812	
TimeOfDayDiena:descriptionSālsstabs	0.213927	0.1047	2.042	0.0411	*
TimeOfDaySaulriets:descriptionSālsstabs	-0.200135	0.1413	-1.416	0.1568	
TimeOfDaySaullekts:descriptionBarotava	-0.010228	0.1252	-0.082	0.9349	
TimeOfDayDiena:descriptionBarotava	-1.591670	0.1464	-10.868	< 0.0001	***
TimeOfDaySaulriets:descriptionBarotava	-0.313522	0.1223	-2.563	0.0103	*
TimeOfDaySaullekts:descriptionIzcirtums	-0.015281	0.2813	-0.054	0.9566	
TimeOfDayDiena:descriptionIzcirtums	0.822959	0.1889	4.355	< 0.0001	***
TimeOfDaySaulriets:descriptionIzcirtums	0.240001	0.2787	0.861	0.3892	

‘.’ – $p = 0.05 - 0.10$, * - $p < 0.05$, ** - $p < 0.001$, *** - $p < 0.0001$



20. Attēls. Izskaidrotā dzīvnieku skaita atkarība no diennakts laika un novietojuma starp vizuālo atpazīšanas un YOLOv5 metodi.

Figure 20. Explained animal count by time of day and viewshed category between visual observation and YOLOv5 method.

Mašīnmācīšanās modelis lielākajā daļā gadījumu dzīvnieku skaitu novērtēja mazāku nekā vizuālā atpazīšana. YOLOv5 modelis uz izcirtuma un ceļa novērtēja vairāk dzīvniekus nekā patiesībā, it īpaši dienas un saulrieta laikā, kā arī barotavā un meža barotavā dienas laikā. Meža barotavai bija lielas atšķirības YOLOv5 noteiktajā skaitā atkarībā no diennakts laikiem, bet sālsstabam, mežam, un meža takai tik izteiktas atšķirības no diennakts laika nav (20. Attēls).

4 Diskusija

Šī pētījuma rezultāti rāda, ka meža kameras novietojumam un diennakts laikam ir būtiska ietekme uz novēroto dzīvnieku daudzumu, un RDI var tikt izmantots, lai novērotu pārnadžu populāciju temporālās un telpiskās izmaiņas šajā ģeogrāfiskajā apgabalā.

Meža kameru RDI sniedza līdzīgus rezultātus pārnadžu populāciju kompozīciju pētāmajā teritorijā salīdzinājumā ar ekskrementu uzskaitēm un bezpilota lidaparātu pārlidojumiem. Pēc meža kameru RDI, mežā visvairāk sastopamie pārnadži ir staltbrīži, ar aptuveni 10 reižu lielāku RDI nekā stirnām, kurām ir divreiz lielāks RDI kā alnim un meža cūkai. Lai gan VMD dotais skaits novērtē lielāku areālu nekā pētāmo teritoriju, un mežziņa dotais skaits ir balstīts uz subjektīvu novērtējumu, iespējama stirnu īpatsvars teritorijā varētu būt lielāks nekā novērtēts ar meža kamerām, jo ir zināms, ka ekskrementu metodes novērtē stirnu populācijas par zemu (Pfeffer et al., 2018), un no bezpilota lidaparātiem stirnas biežāk sajūk ar fonu (Witczuk et al., 2018), un tādējādi netiek uzskaitītas.

Gan diennakts laikam, gan mēnesim, gan meža kameras novietojumam bija statistiski būtiska ietekme uz dzīvnieku novērojumu skaitu, bet diennakts laika un meža kameras novietojumu mijiedarbība spēja izskaidrot gandrīz 70% kopējās datu variācijas. Iespējams, citu faktoru mijiedarbības ievieošana modelī būtu devusi vēl labāku modeli, bet sarežģītākie modeļi uz šīs datu kopas nespēja konverģēties. Dzīvnieku skaits bija būtiski zemāks dienas laikā, it īpaši pie barotavām, bet slēgtajos biotopos kā mežos un meža takās, būtiska korelācija dzīvnieku skaitam ar diennakts laiku netika novērota, un izcirtums bija vienīgais novietojums, kur dienas laikā bija novērots lielāks dzīvnieku skaits. Saulrietā un saullēktā nebija būtiski zemāks skaits nekā naktī, izņemot ceļam saulrietā, un barotavai bija būtiski lielāks skaits naktī nekā visos pārējos diennakts laikos. Tas atbilst literatūrai, jo pārnadžiem ir slēpts dzīvesveids, un tie barojas lielākoties diennakts tumšajā laikā (Tauriņš, 1982, Putman et al., 2011).

Šajā pētījumā veidotais YOLOv5 modelis pareizi atpazīna dzīvnieku klātbūtni un skaitu 44 767 no 55 380 (82%) attēliem. Salīdzinot YOLOv5 modeļa kopējais RDI ar vizuālās novērošanas kopējo RDI, YOLOv5 modeļa uzskaites izskaidroja 51,1% no vizuālās atpazīšanas uzskaišu variācijas, bet pievienojot modelim diennakts laika un novietojuma mijiedarbību, GLMM modelis spēja izskaidrot ($R^2 = 69,7\%$) no kopējās variācijas, kas norāda uz to, ka YOLOv5 modeļa rezultāti var tikt izmantoti teritorijas pārnadžu kopējā RDI

novērtēšanai. YOLOv5 pareizība visaugstākā bija pie barotavas, kur tas spēja labi noteikt gan dzīvnieka klātbūtni, gan arī skaitu. Tam arī bija augsta pareizība novietojumam uz ceļa, jo salīdzinoši daudz attēli bija ar mašīnām, nevis dzīvniekiem. Sliktākā pareizība bija mežā un izcirtumā, jo tajos bija mainīgs fons ar daudz zariem un veģetācijas elementiem, kas palielināja 1. tipa kļūdas. Jāņem vērā, ka lielākā daļa citu pētījumu atsaucas uz apmācības-testa kopas rezultātiem, un bieži neskatās uz modeļa performanci uz ārpus-modeļa datiem, tādējādi samazinot fona ietekmi. Tabak et al. (2019) ieguva 98% pareizību dzīvnieku atpazīšanā Ziemeļamerikā uz 3.3 miljonu lielas attēlu datu bāzes, bet pareizība krita par 16% mēģinot šo modeli attiecināt uz iepriekš neredzētiem attēliem Kanādā.

YOLOv5 modelis spēja detektēt stirnu, alni un mežacūku ar aptuveni 65% pareizību, bet staltbriedi ar 45% pareizību, kuriem bija liels 2. tipa kļūdu daudzums arī apmācības-testa datu kopā. No detektētajiem dzīvniekiem, tas pareizi neklasificēja nevienu alni un tikai 0.01% no staltbriežiem. Tas spēja pareizi klasificēt 70,9% no visām detektētajām meža cūkām, bet 98,2% no visām stirnām. Klasifikācijas rezultātus izskaidro nesabalansētā apmācības datu bāze, kura saturēja ļoti daudz stirnas. Šī iemesla dēļ, modelis vislabāk iemācījās stirnas parametrus, un jutās visdrošāk dzīvnieku tā klasificēt. Apmācības datu kopā sākotnēji bija daudz vairāk staltbriežu, bet dēļ liela 1. tipa daudzuma uz apkārtējās veģetācijas, no datu kopas tika izņemti attēli, kuri aizsedza dzīvniekus. Norouzzadeh et al. (2018) rādīja, ka mašīnmācīšanās modeļi spēj klasificēt dzīvniekus Āfrikā tik pat labi vai labāk kā amatierzinātnieki, ja ir dota pietiekami liela apmācības datu bāze, bet

Lai gan YOLOv5 modelis var tikt pielīdzināts vizuālās atpazīšanas metodei, un spēja analizēt 53 380 attēlu lielo datu kopu 9 stundās, autonomu un pilnvērtīgu pētījumu veikšanai modeļa rezultāti vēl ir jāuzlabo. Potenciāli modeļa uzlabojumi būtu veicami ar iekļautu:

- I. Apmācības datu kopas izlīdzināšanu, lai modelis būtu vienlīdz pārliecināts visu sugu atpazīšanā;
- II. Apmācības datu kopas papildināšanā, it īpaši staltbriedim un alnim un dažādos novietojumos un gadalaikos;
- III. Parametru un apmācības datu izmainīšanā, piemēram ilgākā trenēšanā;
- IV. Apmācības kopai pievienojot tukšus attēlus, un pazeminot modeļa pārliecinātības sliekšni dzīvnieku atpazīšanā.

Ņemot vērā, ka meža kameru pielietojums ekoloģiskos pētījumos būtiski palielinās (Burton et al., 2015), liela mēroga un ilglaicīgiem pētījumi kā Swanson et al. (2015) iekrāj miljoniem attēlu, kuru manuāla analīze aizņemtu vairākus tūkstošus ekspertu stundu. Šo

analīzi var aizstāt dziļās mašīnmācīšanās modeļi, kuri spēj klasificēt attēlus ātrāk, bez noguršanas un bez apstājas.

Carl et al. (2020) jau ir parādījis, ka Eiropas zīdītājus jau var atpazīt ar lielu pareizību apvienojot dzimtu līmenī (kā briežveidīgajos un cūkās), izmantojot pirms tam apmācītus dziļās mašīnmācīšanās modeļus, un (Choiński et al., 2021) ir pierādījis, ka ar YOLOv5 modeli salīdzinoši nelielu (3000 attēlu) datu bāzi, ir iespējams iegūt labus rezultātus Eiropas zīdītāju klasifikācijai. Uzlabojoties mašīnmācīšanās tehnoloģijām un palielinoties anotētām dzīvnieku datu bāzēm, it īpaši Eiropā ar projektiem kā ‘SnapShot’ (Cove et al., 2021) meža kameru datu apstrāde varētu tikt daļēji vai pilnībā automatizēta, padarot meža kameras par lielisku metodi liela mēroga un ilglaicīgām ekoloģiskām monitoringa programmām.

5 Secinājumi

1. Meža kamerās reģistrēto dzīvnieku skaits ir atkarīgs no kameras novietojuma un diennakts laika.
2. YOLOv5 modelis attēlos, kuri nav izmantoti apmācībā, kā pārnadžus spēj atpazīt > 60% staltbriežu, aļņu, un meža cūku, un 45% stirnu, bet dzīvnieku neesamību attēlos nosaka ar 95% precizitāti.
3. Tā kā YOLOv5 modeļa pārnadžu atpazīšanas pareizība attēlos, kuri nav izmantoti apmācībā, pārsniedza 83% un modeļa atpazīto dzīvnieku skaits spēja izskaidrot vairāk kā pusi datu variācijas vizuāli atpazīto dzīvnieku skaitā, meža kameru RDI var tikt izmantots kā indikators pārnadžu temporālām un telpiskām izmaiņām
4. Lai gan YOLOv5 modelis tam pazīstamos attēlos spēja klasificēt detektētās stirnas ar 98% pareizību, bet pārējās sugas ar 53 līdz 85% pareizību, tas nespēj pietiekami labi klasificēt sugas nepazīstamos attēlos, lai tas varētu pilnībā aizstāt vizuālo atpazīšanu

6 Pateicības

Izsaku lielu pateicību darba vadītājam Dr. biol., Asoc. prof. Aināram Auniņam par atsaucību, ieteikumiem, padomiem un norādījumiem darba izstrādē.

Vēlos arī pateikties Vides Risinājumu Institūtam par pētījuma līdzekļu nodrošināšanu, Dainim Jakovelam par padomiem un ieteikumiem, Jevģenijam Fiļipovam un Gvido Prudņikovičam par palīdzību lauka darbos un kameru apsekošanā, un Kadir Aktas par palīdzību modeļa veidošanā un padomu sniegšanā mašīnmācīšanās nozarē.

7 Izmantotā literatūra

- Agrawal, R., Imielinski, T., & Swami, A. (1993). Mining Association in Large Databases. *Proceedings of the 1993 ACM SIGMOD International Conference on Management of Data - SIGMOD '93*, 207–216.
- Andersen, J. (1953). Analysis of a Danish roe deer population (*Capreolus capreolus*) based on the extermination of the total stock. *Dan Rev Game Biol.*, 2, 127–155.
- Anile, S., Ragni, B., Randi, E., Mattucci, F., & Rovero, F. (2014). Wildcat population density on the Etna volcano, Italy: A comparison of density estimation methods. *Journal of Zoology*, 293(4), 252–261. <https://doi.org/10.1111/jzo.12141>
- Apollonio, M., Belkin, V. V., Borkowski, J., Borodin, O. I., Borowik, T., Cagnacci, F., Danilkin, A. A., Danilov, P. I., Faybich, A., Ferretti, F., Gaillard, J. M., Hayward, M., Heshtaut, P., Heurich, M., Hurynovich, A., Kashtalyan, A., Kerley, G. I. H., Kjellander, P., Kowalczyk, R., ... Yanuta, G. (2017). Challenges and science-based implications for modern management and conservation of European ungulate populations. *Mammal Research 2017* 62:3, 62(3), 209–217. <https://doi.org/10.1007/S13364-017-0321-5>
- Apollonio, M., Scandura, M., & Šprem, N. (2014). Reintroductions as a Management Tool for European Ungulates. *Behavior and Management of European Ungulates*, June, 46–77.
- Appolonio, M., Andersen, R., & Putman, R. (2010). *European Ungulates and their Management in the 21st Century*.
- Bennett, L. J., English, P. F., & McCain, R. (1940). A Study of Deer Populations by Use of Pellet-Group Counts. *Wiley on Behalf of the Wildlife Society*, 4(4), 398–403.
- Borkowski, J., Palmer, S. C. F., & Borowski, Z. (2011). Drive counts as a method of estimating ungulate density in forests: Mission impossible? *Acta Theriologica*, 56(3), 239–253. <https://doi.org/10.1007/s13364-010-0023-8>
- Buckland, S. T., Anderson, D. R., Burnham, K. P., Laake, J. L., Borchers, D. L., & Thomas, L. (2011). *Introduction to Distance Sampling*. Oxford University Press. <https://global.oup.com/academic/product/introduction-to-distance-sampling-9780198509271?cc=us&lang=en&>
- Buduma, N., & Locascio, N. (2017). Fundamentals of deep learning. In *O'Reilly Media, Inc* (Vol. 29, Issue 7553). <http://deeplearning.net/>
- Burger, S. V. (2018). *Introduction to Machine Learning with Python with R*. <http://linkinghub.elsevier.com/retrieve/pii/B9780123965028000139>
- Burton, A. C., Neilson, E., Moreira, D., Ladle, A., Steenweg, R., Fisher, J. T., Bayne, E., & Boutin, S. (2015). REVIEW: Wildlife camera trapping: a review and recommendations

- for linking surveys to ecological processes. *Journal of Applied Ecology*, 52(3), 675–685. <https://doi.org/10.1111/1365-2664.12432>
- Carl, C., Schönfeld, F., Profft, I., Klamm, A., & Landgraf, D. (2020). Automated detection of European wild mammal species in camera trap images with an existing and pre-trained computer vision model. *European Journal of Wildlife Research*, 66(4), 1–7. <https://doi.org/10.1007/S10344-020-01404-Y/FIGURES/3>
- Carpio, A. J., Guerrero-Casado, J., Barasona, J. A., & Tortosa, F. S. (2017). Ecological impacts of wild ungulate overabundance on Mediterranean Basin ecosystems. In *Ungulates: Evolution, Diversity and Ecology* (Issue October).
- Caughley, G. (1974). Bias in Aerial Survey. *The Journal of Wildlife Management*, 38(4), 921–933.
- Caughley, G. (1981). What is overabundance. *Problems in Management of Locally Abundant Wild Mammals*, 7–19.
- Chen, G., Han, T. X., He, Z., Kays, R., & Forrester, T. (2014). Deep convolutional neural network based species recognition for wild animal monitoring. *2014 IEEE International Conference on Image Processing, ICIP 2014*, 858–862. <https://doi.org/10.1109/ICIP.2014.7025172>
- Chenais, E., Depner, K., Guberti, V., Dietze, K., Viltrop, A., & Ståhl, K. (2019). Epidemiological considerations on African swine fever in Europe 2014–2018. *Porcine Health Management*, 5(1), 1–10. <https://doi.org/10.1186/s40813-018-0109-2>
- Choiński, M., Rogowski, M., Tynecki, P., Kuijper, D. P. J., Churski, M., & Bubnicki, J. W. (2021). A First Step Towards Automated Species Recognition from Camera Trap Images of Mammals Using AI in a European Temperate Forest. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 12883 LNCS, 299–310. https://doi.org/10.1007/978-3-030-84340-3_24/FIGURES/12
- COŞKUN, M., YILDIRIM, Ö., UÇAR, A., & DEMİR, Y. (2017). AN OVERVIEW OF POPULAR DEEP LEARNING METHODS. *European Journal of Technic*, 7(2), 207–218.
- Cove, M. V., Kays, R., Bontrager, H., Bresnan, C., Lasky, M., Frerichs, T., Klann, R., Lee, T. E., Crockett, S. C., Crupi, A. P., Weiss, K. C. B., Rowe, H., Sprague, T., Schipper, J., Tellez, C., Lepczyk, C. A., Fantle-Lepczyk, J. E., LaPoint, S., Williamson, J., ... McShea, W. J. (2021a). SNAPSHOT USA 2019: a coordinated national camera trap survey of the United States. *Ecology*, 102(6), 2019–2020.

<https://doi.org/10.1002/ecy.3353>

- Cove, M. V., Kays, R., Bontrager, H., Bresnan, C., Lasky, M., Frerichs, T., Klann, R., Lee, T. E., Crockett, S. C., Crupi, A. P., Weiss, K. C. B., Rowe, H., Sprague, T., Schipper, J., Tellez, C., Lepczyk, C. A., Fante-Lepczyk, J. E., LaPoint, S., Williamson, J., ... McShea, W. J. (2021b). SNAPSHOT USA 2019: a coordinated national camera trap survey of the United States. *Ecology*, *102*(6), e03353.
<https://doi.org/10.1002/ECY.3353/SUPPINFO>
- Croon, G. W., McCullough, D. R., Olson, C. E. J., & Queal, L. M. (1968). *Infrared Scanning Techniques for Big Game Censusing*. *32*(4), 751–759.
- Cusack, J. J., Dickman, A. J., Rowcliffe, J. M., Carbone, C., Macdonald, D. W., & Coulson, T. (2015). Random versus game trail-based camera trap placement strategy for monitoring terrestrial mammal communities. *PLoS ONE*, *10*(5).
<https://doi.org/10.1371/journal.pone.0126373>
- Cusack, J. J., Swanson, A., Coulson, T., Packer, C., Carbone, C., Dickman, A. J., Kosmala, M., Lintott, C., & Rowcliffe, J. M. (2015). Applying a random encounter model to estimate lion density from camera traps in Serengeti National Park, Tanzania. *The Journal of Wildlife Management*, *79*(6), 1014. <https://doi.org/10.1002/JWVG.902>
- D'Eon, R. G. (Robert G., Wilson, S. F., Hamilton, D. (Dennis), British Columbia. Ecosystems Branch., & British Columbia. Resources Information Standards Committee. (2006). *Ground-based inventory methods for ungulate snow-track surveys*. *33*, 19.
- Daniels, M. J. (2006). Estimating red deer *Cervus elaphus* populations: An analysis of variation and cost-effectiveness of counting methods. *Mammal Review*, *36*(3), 235–247.
<https://doi.org/10.1111/j.1365-2907.2006.00091.x>
- Dixon, L. K., Sun, H., & Roberts, H. (2019). African swine fever. *Antiviral Research*, *165*, 34–41. <https://doi.org/10.1016/j.antiviral.2019.02.018>
- Dupuis-Desormeaux, M., Davidson, Z., Mwololo, M., Kisio, E., & MacDonald, S. E. (2016). Comparing motion capture cameras versus human observer monitoring of mammal movement through fence gaps: A case study from Kenya. *African Journal of Ecology*, *54*(2), 154–161. <https://doi.org/10.1111/aje.12277>
- Duque, A. B., Santos, L. L. J., Macêdo, D., & Zanchettin, C. (2016). Very Deep Convolutional Neural Networks for Text Classification. *ArXiv Preprint, 11727 LNCS*(June), 193–207. https://doi.org/10.1007/978-3-030-30487-4_16
- Dzięciołowski, R. (1976). Estimating ungulate numbers in a forest by track counts. *Acta Theriologica*, *21*(1975), 217–222. <https://doi.org/10.4098/at.arch.76-20>

- Dzięciołowski, R., Goszczyński, J., Wasilewski, M., & Babińska-Werka, J. (1995). Numbers of red deer in the Słowiński National Park, Poland Introduction Opinions about excessive numbers of deer prevail mostly among foresters. On the other hand real estimates of density are lacking and harvest quota are identified arbitrarily to a la. *Acta Theriologica*, 40(1), 45–51.
- Eggert, L. S., Eggert, J. A., & Woodruff, D. S. (2003). Estimating population sizes for elusive animals: The forest elephants of Kakum National Park, Ghana. *Molecular Ecology*, 12(6), 1389–1402. <https://doi.org/10.1046/j.1365-294X.2003.01822.x>
- Focardi, S., Isotti, R., & Tinelli, A. (2002). Line Transect Estimates of Ungulate Populations in a Mediterranean Forest. *The Journal of Wildlife Management*, 66(1), 48. <https://doi.org/10.2307/3802870>
- Ford, A. T., Clevenger, A. P., & Bennett, A. (2009). Comparison of Methods of Monitoring Wildlife Crossing-Structures on Highways. *Journal of Wildlife Management*, 73(7), 1213–1222. <https://doi.org/10.2193/2008-387>
- Forsyth, D. M., Comte, S., Davis, N. E., Bengsen, A. J., Côté, S. D., Hewitt, D. G., Morellet, N., & Mysterud, A. (2022). Methodology matters when estimating deer abundance: a global systematic review and recommendations for improvements. *The Journal of Wildlife Management*, October 2021, 1–25. <https://doi.org/10.1002/jwmg.22207>
- Géron, A. (2019). Hands-on Machine Learning with Scikit-Learning, Keras and Tensorflow. In *O'Reilly Media, Inc.*
- Gilbert, N. A., Clare, J. D. J., Stenglein, J. L., & Zuckerberg, B. (2020). Abundance estimation of unmarked animals based on camera-trap data. *Conservation Biology*, 00(0), 1–12. <https://doi.org/10.1111/cobi.13517>
- Gomez, A., Salazar, A., & Vargas, F. (2017). Towards automatic wild animal monitoring: Identification of animal species in camera-trap images using very deep convolutional neural networks. *Ecological Informatics*, 41, 24–32. <https://doi.org/10.1016/j.ecoinf.2017.07.004>
- Havens, K. J., & Sharp, E. (2015). *Thermal Imaging Techniques to Survey and Monitor Animals in the Wild: A methodology*. Amsterdam: Academic Press.
- Havens, K. J., Sharp, E. J., Havens, K. J., & Shabp, E. J. (1998). Using Thermal Imagery in the Aerial Survey of Animals Published by : Wiley on behalf of the Wildlife Society Using thermal imagery in the aerial survey of animals. *Wildlife Society Bulletin*, 26(1), 17–23.
- He, Y., & Zhao, J. (2019). Temporal Convolutional Networks for Anomaly Detection in Time

Series. *Journal of Physics: Conference Series*, 1213(4). <https://doi.org/10.1088/1742-6596/1213/4/042050>

- Hindrikson, M., Remm, J., Pilot, M., Godinho, R., Stronen, A. V., Baltrūnaitė, L., Czarnomska, S. D., Leonard, J. A., Randi, E., Nowak, C., Åkesson, M., López-Bao, J. V., Álvares, F., Llaneza, L., Echegaray, J., Vilà, C., Ozolins, J., Rungis, D., Aspi, J., ... Saarma, U. (2017). Wolf population genetics in Europe: a systematic review, meta-analysis and suggestions for conservation and management. *Biological Reviews*, 92(3), 1601–1629. <https://doi.org/10.1111/BRV.12298>
- Howe, E. J., Buckland, S. T., Després-Einspenner, M. L., & Kühl, H. S. (2017). Distance sampling with camera traps. *Methods in Ecology and Evolution*, 8(11), 1558–1565. <https://doi.org/10.1111/2041-210X.12790>
- Hubel, D. H. (1959). Single unit activity in striate cortex of unrestrained cats. *The Journal of Physiology*, 147(2), 226–238. <https://doi.org/10.1113/jphysiol.1959.sp006238>
- Imperio, S., Ferrante, M., Grignetti, A., Santini, G., & Focardi, S. (2010). Investigating population dynamics in ungulates: Do hunting statistics make up a good index of population abundance? *Wildlife Biology*, 16(2), 205–214. <https://doi.org/10.2981/08-051>
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2015). An Introduction to Statistical Learning. In *Springer*. <https://doi.org/10.1016/j.peva.2007.06.006>
- Jenks, K. E., Chanteap, P., Damrongchainarong, K., Cutter, P., Cutter, P., Redford, T., Lynam, A. J., Howard, J. G., & Leimgruber, P. (2011). Using Relative Abundance Indices from Camera-Trapping to Test Wildlife Conservation Hypotheses – An Example from Khao Yai National Park, Thailand: <Http://Dx.Doi.Org/10.1177/194008291100400203>, 4(2), 113–131. <https://doi.org/10.1177/194008291100400203>
- Jocher, G., Chaurasia, A., Stoken, A., Borovec, J., NanoCode012, Kwon, Y., TaoXie, Fang, J., imyhxy, Michael, K., Lorna, V, A., Montes, D., Nadar, J., Laughing, tkianai, yxNONG, Skalski, P., Wang, Z., ... Minh, M. T. (2022). *ultralytics/yolov5: v6.1 - TensorRT, TensorFlow Edge TPU and OpenVINO Export and Inference*. <https://doi.org/10.5281/ZENODO.6222936>
- Johann, F., Handschuh, M., Linderoth, P., Heurich, M., Dormann, C. F., & Arnold, J. (2020). Variability of daily space use in wild boar *Sus scrofa*. <Https://Doi.Org/10.2981/Wlb.00609>, 2020(1). <https://doi.org/10.2981/WLB.00609>
- Jones, I., Pearlsstine, L., & Percival, H. F. (2006). An assessment of small unmanned aerial vehicles for wildlife research. *Wildl. Soc.*

- Karpathy, A., Toderici, G., Shetty, S., Leung, T., Sukthankar, R., & Li, F. F. (2014). Large-scale video classification with convolutional neural networks. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 1725–1732. <https://doi.org/10.1109/CVPR.2014.223>
- Keeping, D., & Pelletier, R. (2014). Animal density and track counts: Understanding the nature of observations based on animal movements. *PLoS ONE*, 9(5), 1–11. <https://doi.org/10.1371/journal.pone.0096598>
- Kie, J G. (1988). Performance in wild ungulates: measuring population density and condition of individuals. *U.S. Department of Agriculture*, 17. <http://www.treesearch.fs.fed.us/pubs/27289/>
- Kie, John G., & White, M. (1985). Population Dynamics of White-Tailed Deer (*Odocoileus virginianus*) on the Welder Wildlife Refuge, Texas. *The Southwestern Naturalist*, 30(1), 105–118.
- Kim, Y., Jung, J. W., Kim, J. U., Oh, Y. S., Chung, H., & Kim, J. H. (2022). Dietary niche partitioning in brown skuas (*Stercorarius lonnbergi*) during the chick-rearing period at Narębski Point on King George Island, Antarctica. *Polar Biology*, 45(1), 153–158. <https://doi.org/10.1007/s00300-021-02971-9>
- Kitamura, S. (2015). *Mammal diversity and conservation in a small isolated forest of southern*. 58(March), 145–156.
- KOSTER, S. H., & HART, J. A. (1988). Methods of estimating ungulate populations in tropical forests. *African Journal of Ecology*, 26(2), 117–126. <https://doi.org/10.1111/j.1365-2028.1988.tb00962.x>
- Krizhevsky, A., Sutskever, I., & Sutskever, I. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems*, 25. <https://doi.org/10.1201/9781420010749>
- Kucera, E. (1976). Deer flushing distance as related to observer's mode of travel. *Wildlife Society Bulletin*, 128–129.
- Kusak, J., & Krapinec, K. (2010). *Ungulates and their management in Croatia*. Cambridge University Press.
- Kušta, T., Keken, Z., Ježek, M., Holá, M., & Šmíd, P. (2017). The effect of traffic intensity and animal activity on probability of ungulate-vehicle collisions in the Czech Republic. *Safety Science*, 91, 105–113. <https://doi.org/10.1016/j.ssci.2016.08.002>
- LaFleur, M., & Pebsworth, P. A. (2017). Camera Traps. *The International Encyclopedia of Primatology*, 1–3. <https://doi.org/10.1002/9781119179313.wbprim0281>

- LeResche, R. E., & Rausch, R. A. (1974). *Accuracy and Precision of Aerial Moose Censusing*. *38*(2), 175–182.
- Lhoest, S., Linchant, J., Quevauvillers, S., Vermeulen, C., & Lejeune, P. (2015). How many hippos (Homhip): Algorithm for automatic counts of animals with infra-red thermal imagery from UAV. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, *40*(3W3), 355–362.
<https://doi.org/10.5194/isprsarchives-XL-3-W3-355-2015>
- Li, S., Mcshea, W. J., Wang, D., Huang, J., & Shao, L. (2012). A direct comparison of camera-trapping and sign transects for monitoring wildlife in the wanglang national nature Reserve, China. *Wildlife Society Bulletin*, *36*(3), 538–545.
<https://doi.org/10.1002/wsb.161>
- Lin, H. (1998). Information To Users Umi. *Dissertation, Ph.D. Thes*(Structural Biology and Molecular Biophysics, University of Pennsylvania, PA, USA.), 274.
- Lin, T. Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P., & Zitnick, C. L. (2014). Microsoft COCO: Common Objects in Context. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, *8693 LNCS*(PART 5), 740–755.
<https://doi.org/10.48550/arxiv.1405.0312>
- Linchant, J., Lisein, J., Semeki, J., Lejeune, P., & Vermeulen, C. (2015). Are unmanned aircraft systems (UASs) the future of wildlife monitoring? A review of accomplishments and challenges. *Mammal Review*, *45*(4), 239–252. <https://doi.org/10.1111/mam.12046>
- Lovari, S., Serrao, G., & Mori, E. (2017). Woodland features determining home range size of roe deer. *Behavioural Processes*, *140*, 115–120.
<https://doi.org/10.1016/J.BEPROC.2017.04.012>
- Lowe, V. P. W. (1969). Population Dynamics of the Red Deer (*Cervus elaphus* L.) on Rhum. *The Journal of Animal Ecology*, *38*(2), 425. <https://doi.org/10.2307/2782>
- Macdonald, D. W. (2001). *The Encyclopedia of Mammals* (3rd ed.). Oxford University Press.
- Mace, R. D., Minta, S. C., Manley, T. L., & Aune, K. E. (1994). Estimating Grizzly Bear Population Size Using Camera Sightings. *Wildlife Society Bulletin*, *22*(1), 74–83.
- McCulloch, W. S., & Pitts, W. (1943). A LOGICAL CALCULUS OF THE IDEAS IMMANENT IN NERVOUS ACTIVITY. *The Bulletin of Mathematical Biophysics*, *5*, 115–133. https://doi.org/10.1007/978-3-030-01370-7_61
- Meek, P. D., Ballard, G. A., Sparkes, J., Robinson, M., Nesbitt, B., & Fleming, P. J. S. (2019). Camera trap theft and vandalism: occurrence, cost, prevention and implications

- for wildlife research and management. *Remote Sensing in Ecology and Conservation*, 5(2), 160–168. <https://doi.org/10.1002/RSE2.96>
- Miao, Z., Gaynor, K. M., Wang, J., Liu, Z., Muellerklein, O., Norouzzadeh, M. S., McInturff, A., Bowie, R. C. K., Nathan, R., Yu, S. X., & Getz, W. M. (2019). Insights and approaches using deep learning to classify wildlife. *Scientific Reports*, 9(1), 1–9. <https://doi.org/10.1038/s41598-019-44565-w>
- Mikołajczyk, A., & Grochowski, M. (2018). Data augmentation for improving deep learning in image classification problem. *2019 International Interdisciplinary PhD Workshop, IIPhDW 2019*, 117–122.
- Mitchell, T. (1997). Machine learning. In *McGraw Hill*. https://doi.org/10.1007/978-981-13-9113-2_15
- Moeller, A. K., Lukacs, P. M., & Horne, J. S. (2018). Three novel methods to estimate abundance of unmarked animals using remote cameras. *Ecosphere*, 9(8), e02331. <https://doi.org/10.1002/ECS2.2331>
- Mulero-Pázmány, M., Stolper, R., Van Essen, L. D., Negro, J. J., & Sassen, T. (2014). Remotely piloted aircraft systems as a rhinoceros anti-poaching tool in Africa. *PLoS ONE*, 9(1), 1–10. <https://doi.org/10.1371/journal.pone.0083873>
- Nepal, U., & Eslamiat, H. (2022). Comparing YOLOv3, YOLOv4 and YOLOv5 for Autonomous Landing Spot Detection in Faulty UAVs. *Sensors*, 22(2). <https://doi.org/10.3390/s22020464>
- Norouzzadeh, M. S., Nguyen, A., Kosmala, M., Swanson, A., Palmer, M. S., Packer, C., & Clune, J. (2018). Automatically identifying, counting, and describing wild animals in camera-trap images with deep learning. *Proceedings of the National Academy of Sciences of the United States of America*, 115(25), E5716–E5725. https://doi.org/10.1073/PNAS.1719367115/SUPPL_FILE/PNAS.1719367115.SAPP.PDF
- O'Brien, T. G., Kinnaird, M. F., & Wibisono, H. T. (2003). Crouching tigers, hidden prey: Sumatran tiger and prey populations in a tropical forest landscape. *Animal Conservation*, 6(2), 131–139. <https://doi.org/10.1017/S1367943003003172>
- Parsons, A. W., Forrester, T., McShea, W. J., Baker-Whatton, M. C., Millspaugh, J. J., & Kays, R. (2017). Do occupancy or detection rates from camera traps reflect deer density? *Journal of Mammalogy*, 98(6), 1547–1557. <https://doi.org/10.1093/JMAMMAL/GYX128>
- Patel, A. A. (2019). Hands-On Unsupervised Learning Using Python. In *O'Reilly*.

- Patterson, J., & Gibson, A. (2017). *Deep Learning*. O'Reilly Media, Inc.
- Pettorelli, N., Lobora, A. L., Msuha, M. J., Foley, C., & Durant, S. M. (2010). Carnivore biodiversity in Tanzania: revealing the distribution patterns of secretive mammals using camera traps. *Animal Conservation*, *13*(2), 131–139. <https://doi.org/10.1111/J.1469-1795.2009.00309.X>
- Pfeffer, S. E., Spitzer, R., Allen, A. M., Hofmeester, T. R., Ericsson, G., Widemo, F., Singh, N. J., & Croomsigt, J. P. G. M. (2018). Pictures or pellets? Comparing camera trapping and dung counts as methods for estimating population densities of ungulates. *Remote Sensing in Ecology and Conservation*, *4*(2), 173–183. <https://doi.org/10.1002/RSE2.67>
- Pollock, K. H. (1980). *Capture-recapture models: a review of current methods, assumptions and experimental design* (p. 32).
- Putman, R., Apollonio, M., & Andersen, R. (2011). *Ungulate Management in Europe*. Cambridge University Press. <https://doi.org/10.1017/CBO9780511974137>
- Putman, R., Apollonio, M., Andersen, R., & Reimoser, F. (2011). Impacts of wild ungulates on vegetation: costs and benefits. *Ungulate Management in Europe: Problems and Practices*.
- Roque, D. V., Göttert, T., Macandza, V. A., & Zeller, U. (2021). Assessing distribution patterns and the relative abundance of reintroduced large herbivores in the limpopo national park, Mozambique. *Diversity*, *13*(10). <https://doi.org/10.3390/d13100456>
- Rovero, F., & Rathbun, G. B. (2006). a Potentially New Giant Sengi (Elephant-Shrew) From the Udzungwa Mountains, Tanzania. *Journal of East African Natural History*, *95*(2), 111–115. [https://doi.org/10.2982/0012-8317\(2006\)95\[111:apngse\]2.0.co;2](https://doi.org/10.2982/0012-8317(2006)95[111:apngse]2.0.co;2)
- Rovero, F., Zimmermann, F., Berzi, D., & Meek, P. (2013). “Which camera trap type and how many do I need?” A review of camera features and study designs for a range of wildlife research applications. *Hystrix*, *24*(2). <https://doi.org/10.4404/hystrix-24.2-6316>
- Royle, J. A. (2004). N-Mixture Models for Estimating Population Size from Spatially Replicated Counts. *Biometrics*, *60*(1), 108–115. <https://doi.org/10.1111/J.0006-341X.2004.00142.X>
- Royle, J. A., Chandler, R. B., Sollmann, R., & Gardner, B. (2013). *Spatial Capture-Recapture* -. Elsevier. https://books.google.lv/books?hl=lv&lr=&id=RO08-S-amZMC&oi=fnd&pg=PR1&dq=Royle+JA,+Chandler+RB,+Sollman+R,+Gardner+B.+2014.+Spatial+capture+recapture&ots=e9vsPkJA-F&sig=FPgRVuH045bYLMuUIHkQ0QPiwqM&redir_esc=y#v=onepage&q&f=false
- Royle, J. A., & Nichols, J. D. (2003). Estimating abundance from repeated presence-absence

- data or point counts. *Ecology*, 84(3), 777–790. [https://doi.org/10.1890/0012-9658\(2003\)084\[0777:EAFRPA\]2.0.CO;2](https://doi.org/10.1890/0012-9658(2003)084[0777:EAFRPA]2.0.CO;2)
- Ruiz-Fons, F., Sánchez-Matamoros, A., Gortázar, C., & Sánchez-Vizcaíno, J. M. (2014). The role of wildlife in bluetongue virus maintenance in Europe: Lessons learned after the natural infection in Spain. *Virus Research*, 182, 50–58. <https://doi.org/10.1016/J.VIRUSRES.2013.12.031>
- Sáenz-de-Santa-María, A., & Tellería, J. L. (2015). Wildlife-vehicle collisions in Spain. *European Journal of Wildlife Research*, 61(3), 399–406. <https://doi.org/10.1007/S10344-015-0907-7/TABLES/2>
- Scher, S., & Messori, G. (2018). Predicting weather forecast uncertainty with machine learning. *Quarterly Journal of the Royal Meteorological Society*, 144(717), 2830–2841. <https://doi.org/10.1002/qj.3410>
- Simonyan, K., & Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, 1–14.
- Skriba, G. (2011). *Staltbriežu izcelsme, izplatība un audzēšana Latvijā*. Jelgavas tipogrāfija.
- Smart, J. C. R., Ward, A. I., & White, P. C. L. (2004). Monitoring woodland deer populations in the UK: An imprecise science. *Mammal Review*, 34(1–2), 99–114. <https://doi.org/10.1046/j.0305-1838.2003.00026.x>
- Smit, C. (2011). *Large herbivores as 'Environmental Engineers.'* Ungulate Management in Europe; Problems and Practices.
- Smith, D. (2012). *Animal pests : faecal pellet counts*. 1–10.
- Sollmann, R., Mohamed, A., Samejima, H., & Wilting, A. (2013). Risky business or simple solution – Relative abundance indices from camera-trapping. *Biological Conservation*, 159, 405–412. <https://doi.org/10.1016/J.BIOCON.2012.12.025>
- Spura, Z. (1974). *Latvijas dzīvnieku pasaule*. Liesma.
- Swanson, A., Kosmala, M., Lintott, C., Simpson, R., Smith, A., & Packer, C. (2015). Snapshot Serengeti, high-frequency annotated camera trap images of 40 mammalian species in an African savanna. *Scientific Data 2015 2:1*, 2(1), 1–14. <https://doi.org/10.1038/sdata.2015.26>
- Tabak, M. A., Norouzzadeh, M. S., Wolfson, D. W., Sweeney, S. J., Vercauteren, K. C., Snow, N. P., Halseth, J. M., Di Salvo, P. A., Lewis, J. S., White, M. D., Teton, B., Beasley, J. C., Schlichting, P. E., Boughton, R. K., Wight, B., Newkirk, E. S., Ivan, J. S., Odell, E. A., Brook, R. K., ... Miller, R. S. (2019). Machine learning to classify animal

- species in camera trap images: Applications in ecology. *Methods in Ecology and Evolution*, 10(4), 585–590. <https://doi.org/10.1111/2041-210X.13120>
- Tack, J. (2018). *Wild Boar (Sus scrofa) populations in Europe: a scientific review of population trends and implications for management*. (p. 56). European Landowners' Organization.
- Tanwar, K. S., Sadhu, A., & Jhala, Y. V. (2021). Camera trap placement for evaluating species richness, abundance, and activity. *Scientific Reports*, 11(1), 1–12. <https://doi.org/10.1038/s41598-021-02459-w>
- Tauriņš, E. (1982). *Latvijas zīdītājdzīvnieki*. Zvaigzne.
- Taylor, J. C., Bates, S. B., Whiting, J. C., McMillan, B. R., & Larsen, R. T. (2022). Using camera traps to estimate ungulate abundance: a comparison of mark–resight methods. *Remote Sensing in Ecology and Conservation*, 8(1), 32–44. <https://doi.org/10.1002/rse2.226>
- Thurfjell, H., Spong, G., Olsson, M., & Ericsson, G. (2015). Avoidance of high traffic levels results in lower risk of wild boar-vehicle accidents. *Landscape and Urban Planning*, 133, 98–104. <https://doi.org/10.1016/J.LANDURBPLAN.2014.09.015>
- Trolle, M., Noss, A. J., Cordeiro, J. L. P., & Oliveira, L. F. B. (2008). Brazilian tapir density in the Pantanal: A comparison of systematic camera-trapping and line-transect surveys. *Biotropica*, 40(2), 211–217. <https://doi.org/10.1111/j.1744-7429.2007.00350.x>
- Tucker, M. A., Böhning-Gaese, K., Fagan, W. F., Fryxell, J. M., Van Moorter, B., Alberts, S. C., Ali, A. H., Allen, A. M., Attias, N., Avgar, T., Bartlam-Brooks, H., Bayarbaatar, B., Belant, J. L., Bertassoni, A., Beyer, D., Bidner, L., Van Beest, F. M., Blake, S., Blaum, N., ... Mueller, T. (2018). Moving in the Anthropocene: Global reductions in terrestrial mammalian movements. *Science*, 359(6374), 466–469. https://doi.org/10.1126/SCIENCE.AAM9712/SUPPL_FILE/AAM9712_TUCKER_SM.PDF
- Valente, A. M., Acevedo, P., Figueiredo, A. M., Fonseca, C., & Torres, R. T. (2020). Overabundant wild ungulate populations in Europe: management with consideration of socio-ecological consequences. *Mammal Review*, 50(4), 353–366. <https://doi.org/10.1111/MAM.12202>
- Valsts Meža Dienests. 2021. Skaitļi un fakti. <https://www.vmd.gov.lv/valsts-meza-dienests/statiskas-lapas/medibas/valsts-meza-dienests/statiskas-lapas/skaitli-un-fakti?id=766#jump> (skatīts: 03.03.2022.)

- Wegge, P., Pokheral, C. P., & Jnawali, S. R. (2004). Effects of trapping effort and trap shyness on estimates of tiger abundance from camera trap studies. *Animal Conservation Forum*, 7(3), 251–256. <https://doi.org/10.1017/S1367943004001441>
- Wiebke, N., Widemo, F., Singh, N. J., Seiler, A., & Crooms, J. P. G. M. (2020). Strength of correlation between wildlife collision data and hunting bags varies among ungulate species and with management scale. *European Journal of Wildlife Research*, 66(6). <https://doi.org/10.1007/s10344-020-01421-x>
- Witczuk, J., Pagacz, S., Zmarz, A., & Cypel, M. (2018). Exploring the feasibility of unmanned aerial vehicles and thermal imaging for ungulate surveys in forests - preliminary results. *International Journal of Remote Sensing*, 39(15–16), 5504–5521. <https://doi.org/10.1080/01431161.2017.1390621>
- Yapıcı, M. M., Tekerek, A., & Topaloğlu, N. (2019). Literature Review of Deep Learning Research Areas. *Gazi Journal of Engineering Sciences*, 5(3), 188–215. <https://doi.org/10.30855/gmbd.2019.03.01>

Maģistra darbs „Savvaļas pārnadžu populācijas novērtēšana, izmantojot vizuālo atpazīšanu meža kameru datus, un salīdzināšana ar apmācītas mašīnmācīšanās modeļa rezultātu.” izstrādāts LU Bioloģijas fakultātē.

Ar savu parakstu apliecinu, ka pētījums veikts patstāvīgi, izmantoti tikai tajā norādītie informācijas avoti un iesniegtā darba elektroniskā kopija atbilst izdrukai.

Autors: Alekss Vecvanags *paraksts* 26.05.2022.

Rekomendēju darbu aizstāvēšanai

Vadītājs: asoc. prof., Dr.biol. Ainārs Auniņš *paraksts* 26.05.2022.

Recenzents: *paraksts* asoc. prof., Dr.biol. Viesturs Vintulis

Darbs iesniegts LU Bioloģijas fakultātē 26.05.2022.

Lietvede: *paraksts*

Darbs aizstāvēts Bioloģijas maģistra gala pārbaudījuma komisijas sēdē

prot. Nr. , vērtējums

Komisijas sekretārs/e: