


Skattning av röjningsbehov med digitala verktyg

Kari Hyll, Liviu Ene, Rikard Hedberg, Filippa Sidén, Martin Längkvist,
Atiqur Rahaman, Erik Willén, Maria Nordström



Bildcollage av oröjt objekt, röjare med karta (fotograf: Erik Viklund), GNSS-koordinater och färgdiagram över röjningstid.

Innehåll

Förord	5
Sammanfattning.....	6
Summary	7
Bakgrund	8
Röjning	8
Prediktion och maskininlärning	9
Skattning av röjningsbehov.....	9
Visuell bedömning	9
Satellitbaserad skattning	10
Drönbaserad skattning.....	11
LiDAR-baserad skattning och kombinationsmetoder	11
Sammanfattning av litteraturen	11
Syfte och målbild	12
Material	12
Röjningsobjekt	12
Tränings- och valideringsobjekt.....	12
Avverkningsår	20
Röjningskoordinater och tid	20
Insamling	20
GDPR.....	21
Filtrering av ungsågsröjningsobjekt.....	21
Omsampling.....	23
Röjsågsdata.....	23
Introduktion.....	23
Beskrivning	24
Datainsamling röjsågsdata.....	26
Matchning av röjsågsdata och GNSS-koordinater	26
Multispektrala satellitdata.....	27
Beskrivning	27
Datainsamling multispektrala satellitdata.....	28
Tidsserie och filtrering av molniga bilder	29
Bivariabler	31
Marktäcke klass	31

Markfuktighetskartan (DTW).....	32
Trädhöjd	32
Lutning.....	33
Metoder	33
Hypotes.....	33
Fältreferensdata	33
Framtagning av färgdiagram.....	33
Modellering.....	36
Olika testade metoder	36
AI-modellen	36
Validering i fält.....	38
Resultat	39
Modell av röjningsbehov	39
Kvalitativ validering i fält.....	40
Diskussion	41
Osäkerheter och utmaningar i fältdatainsamlingen	41
Utmaningar med rasterdata från Sentinel-2.....	42
Modellens användbarhet och möjlig implementering	43
Andra användningsområden för de insamlade fältdata	44
Avslutande reflektioner	44
Vidare arbete	45
Slutsatser	46
Referenser.....	47
Appendix A – Alternativ metodik	49
Appendix B - Fälthinstruktion RøjSat v. 1.1.....	56
Appendix C	1



Uppsala Science Park, 751 83 Uppsala
skogforsk@skogforsk.se
skogforsk.se

Kvalitetsgranskning (Intern peer review) har genomförts i februari 2024 av Henrik Persson, seniorforskare. Därefter har Magnus Thor, Forskningschef, granskat och godkänt publikationen för publicering den 19 april 2024.

Redaktör: Caroline Rothpfeffer, caroline.rothpfeffer@skogforsk.se
©Skogforsk 2024 ISSN 1404-305X

Förord

Författarna vill tacka alla som har varit involverade i projektet. Skogsföretagens representanter Erik Eklund och Björn Karlborg (Södra), Johan Ekenstedt och Marcus Abrahamsson Månsson (Sveaskog) samt Erik Viklund (Mellanskog) tackas, liksom de arbetslag inom skogsvård som har ställt upp och genomfört fältdatainsamlingen. Vi vill tacka Husqvarna Digital Development (Husqvarna Fleet Services) och Husqvarna HandHeld Development (Husqvarna Forest & Garden Division) för deras engagemang i projektet och bidrag med röjsågar samt Fleet-tjänsterna. Från Örebro Universitet tackas Marjan Alirezaie, Amy Loutfi och Emma Svensson.

Vi tackar Vinnova och utlysningen *Från AI-forskning till innovation våren 2019* för deras finansiella bidrag till projektet.

Uppsala april 2024

Kari Hyll (Skogforsk), Liviu Ene (Skogforsk), Rikard Hedberg (Field Group), Filippa Sidén (Field Group), Martin Längkvist (Örebro Universitet), Atiqur Rahaman (Örebro Universitet), Erik Willén (StoraEnso), Maria Nordström (Skogforsk).

Sammanfattning

Röjning av skog i ungskogsfasen (2-4 m höga skogar) ger positiv effekt på lönsamheten redan i de första uttagen av gagnvirke (gallring). Utvecklingen i äldre skogar kan till viss del förutsägas, men i ungskogar krävs fältbesök för att bedöma åtgärdsbehov. Enligt Skogsstyrelsens analyser av riksskogstaxeringens fältinventeringar finns ett röjningsbehov över mer än 1 miljon hektar i Sverige om målet för skogsskötseln är optimal ekonomisk avkastning. Det innebär också att behovet ökar årligen i takt med att röjning genomförs i för låg omfattning. Skogsföretag känner till behovet och röjer i sina egna skogar, men det röjs betydligt mindre i privata skogsägares innehav. Det kan också vara svårt för arbetslag inom skogsvård att planera röjningen till följd av odetailerad information om objekten.

Svenska skogsföretag karterar idag röjningsbehov genom att först göra ett urval baserat på registerdata och sedan bruka helikopterinventering med visuella bedömningar över sina arealer. Med tanke på det återkommande behovet av inventering (årligen) och den stora ytan att täcka är detta väldigt ineffektivt och utförs inte alltid, vilket får effekten att färre skogar röjs än om effektiva metoder för kartering av röjningsbehov hade funnits. Skogsstyrelsen har använt vegetationsindex från satellitdata (en tidpunkt) för att identifiera röjningsbehov i utförda avverkningar (5-15 år efter avverkning). Karteringen omfattar endast några skogstyper och fungerar bara över delar av Sverige. Myndigheten har dock kunnat mäta ökad röjningsaktivitet när de nyttjat karteringen i sin rådgivning. Tjänsteföretag erbjuder också röjningskartor från fjärranalys i begränsad omfattning. Gemensamt har varit en brist på detaljerade fältdata att validera mot.

En betydande del av projektet var en detaljerad fältdatainsamling där röjningsarbetare i tre arbetslag verksamma i tre olika geografiska områden försågs med en koordinat- och tidsloggande mobilapp, samt att röjsågar utrustades med en varvtalsloggande sensor. Vidare fick arbetslagen instruktioner för hur de skulle beskriva och dokumentera objekten. I denna rapport beskrivs hur data från ett av de tre geografiska områdena tillsammans med satellitbilder och kartor över trädhöjd, markfuktighet och lutning användes för att träna en AI-modell till att prediktera röjningsbehov.

Huvudresultatet är en djupinlärningsmodell som predikterar röjningsbehov uttryckt som tidsåtgång i sekunder per pixel i ungskogar, tränad på objekt i Södra Sverige. Medelfelet för modellen per 10×10 meters pixel är 56,1 sekunders röjtid. Denna lokala modell har potential att vidareutvecklas för att användas som beslutsstöd för skogsvårdsentreprenörer som utför arbetet, men även för skogsföretag i planeringen av insatserna. Modell bör utvärderas vidare mot fältmätningar under exempelvis en säsong innan operationell användning.

Möjliga nästa steg inkluderar att testa befintlig modell på ytterligare områden, träna modellen på satellitbilder från flera delar av Sverige, flera säsonger eller från efter röjningstillfället, utforska olika sätt att presentera prediktionen samt andra tillämpningar av datasetet, till exempel för att utveckla arbetsmetodiken vid röjning.

Summary

Pre-commercial thinning in the young forest phase (trees 2-4 m high) has a positive effect on profitability as early as the first extraction of commercially valuable timber (thinning). Development in older forests can be forecasted to a certain extent, but in young forests field visits are needed to assess the need for any measures. According to the Swedish Forest Agency's analyses of field data from the Swedish National Forest Inventory, pre-commercial thinning is needed on more than 1 million hectares in Sweden if the objective of forestry is optimal economic return. This also means that the need is increasing annually, as the rate of pre-commercial thinning is too low. Forest companies are aware of this need, and carry out pre-commercial thinning in their forests, but much less pre-commercial thinning takes place on private forest owner holdings. It can also be difficult for forestry work teams to plan pre-commercial thinning because of the lack of detailed information about the site.

Today, Swedish forest companies map needs for pre-commercial thinning by first selecting sites using register data and then using helicopter inventories with visual assessment over their forest areas. In view of the recurring need for inventories (annually) and the large area to cover, this is a highly inefficient method and is not always carried out. The result is that fewer forests are pre-commercially thinned than would be the case if efficient methods for mapping pre-commercial thinning needs were available.

The Swedish Forest Agency has used vegetation indices from satellite data (single time point) to identify pre-commercial thinning needs 5-15 years after clearcutting. The mapping only covers certain forest types and only works for parts of Sweden. However, the agency has been able to measure increased pre-commercial thinning activity when they have used the mapping in their advisory service. Service companies also offer pre-commercial thinning maps derived from remote sensing, but only to a small extent. What is common is a lack of detailed field data against which to validate their data.

A significant part of this project involved collecting detailed field data. Pre-commercial thinning workers in three teams, working in three different geographical areas, were equipped with a mobile app showing coordinates and a time log, and cleaning saws were fitted with a sensor that logs engine speed. The teams were also instructed on how to describe and take photos of the site. This report describes how data from one of the three geographical areas, together with satellite images and maps of tree height, ground moisture and slope, were used to train an AI model for predicting the need for pre-commercial thinning.

The main outcome is a deep learning model that predicts pre-commercial thinning needs, expressed as time in seconds per pixel in young forest, trained on forest sites in southern Sweden. The standard error for the model per 10×10 -m pixel is 56.1 seconds of pre-commercial thinning. This local model has potential to be further developed for use as decision support for forest contractors performing the work, but also for forest companies when planning measures. The model should therefore be evaluated in relation to field measurements over, for example, one season before use in operations.

Possible next steps include evaluating the existing model in other areas, training the model on satellite images from more parts of Sweden and over more seasons. After pre-commercial thinning, explore different ways of presenting the predictions and other applications of the dataset, for example, in developing work methods for pre-commercial thinning.

Bakgrund

Röjning

Röjning är en avverkning av unga eller klena träd utan ekonomiskt uttag i form av gagnvirke. Biomassan lämnas kvar i skogen och näring, vatten och ljus frigörs till de träd som bedöms ha bäst förutsättningar. Den ekonomiska vinsten sker på längre sikt. Det finns tre typer av röjning, där ungskogsröjningen är den dominerande (Figur 1).

Plantskogsröjning	Ungskogsröjning	Underväxtröjning
• Medelhöjden på de större träden < 1,3 meter vid röjning • Görs när beståndet är 0,5–1 meter högt	• Jämna bestånd: första röjningen vid 3–5 m trädhöjd • Ojämna bestånd: första röjning vid c:a 2–3 m höjd, andra röjning vid 6–10 m höjd • Vanlig trädålder 5-15 år, beroende på plats	• Röjning innan slutavverkning, för att förbättra framkomlighet

Figur 1. Olika röjningstyper. Denna rapport fokuserar på ungskogsröjning (Pettersson m.fl. 2012).

Röjning utförs vanligen motormanuellt med röjsåg. Ett objekt kan ta allt från några timmar till flera arbetsdagar att röja. Exempel på faktorer som påverkar tidsåtgången för röjning listas i Tabell 1.

Tabell 1. Faktorer som påverkar tidsåtgången för röjning.

Faktor	Kommentar
Stamantal	Om stammarna står tätt blir tidsåtgången för röjning större
Lövträd	Ett vanligt scenario är att röjning utförs för att främja tall eller gran, och det är då till stor del lövträd som behöver röjas bort. En eftersatt röjning innebär ofta att lövträden står tätt och röjningen tar därmed längre tid
Lutning	Det tar i regel längre tid att röja i sluttningar
Blockighet	Det tar i regel längre tid att röja i blockig terräng
Avstånd till väg	Påverkar tid det tar att hämta vatten, mat, verktyg m.m. under en arbetsdag
Erfarenhet hos arbetslaget	Påverkar hur effektivt man röjer. Detta inkluderar arbetsmönster, dagliga rutiner och att ha optimal utrustning för uppgiften

Röjningen i Sverige är eftersatt, det vill säga mycket ungskog står kvar trots att den borde ha röjts ifall målet med skogsskötseln är största möjliga virkesavkastning.

Prediktion och maskininlärning

Prediktion innebär att göra en kvalificerad gissning av ett utfall baserat på en modell. Modellen tränas på en del av data och valideras på en annan del av data. Inom maskininlärning, där AI ingår, brukar modeller delas upp i regressionsmodeller och klassificeringsmodeller. Regressionsmodeller innebär att utfallet predikteras som kontinuerliga värden, till exempel antal millimeter nederbörd i en vädermodell eller trädslagsvisa volymer i Skogliga Grunddata. För röjning skulle utfallet kunna vara antalet sekunder det tar att röja ett område. Regressionsmodeller kräver ofta mer data än klassificeringsmodeller.

Klassificeringsmodeller innebär att utfallet predikteras i två eller flera klasser till exempel generell väderlek i en vädermodell ("övervägande molnigt", "soligt", "molnigt") eller klassning i skogstyper som lövskog eller granskog i Nationella Marktäckedata. Klassificeringsmodeller brukar delas upp vidare i binär klassificering, med två klasser, och multiklass-klassificering, med fler än två klasser. För röjning skulle en binär klassificering kunna vara "inget röjningsbehov" och "röjningsbehov", medan en multiklass-klassificering skulle kunna vara "inget röjningsbehov", "litet röjningsbehov", "stort röjningsbehov".

Exempel på klassiska maskininlärningsmodeller är Random Forest, Support Vector Machines (SVM), Gradient boosting och Logistic Regression. Dessa typer av modeller tränas på data i tabulär form, tänk Excel-ark, där varje kolumn är en variabel. Om variablerna är tvådimensionella bilder måste de därför "plattas ut" till en lång kolumn. Exempel på AI-modeller eller artificiella neurala nätverk är Convolutional Neural Networks (CNN), Recurrent Neural Networks (RNN) och Multilayer Perceptrons (MLP). Neurala nätverk tränas ibland på tabulära data och ibland på tvådimensionella bilder där modellen i det senare fallet kan nyttja rumsliga samband mellan pixlarna. En modell anpassad för tvådimensionella bilder kräver ofta att alla bilder har samma fyrkantiga sidolängd om 2^x pixlar. Det gör det mer omständligt att använda den typen av modeller. Hur mycket data en maskininlärningsmodell behöver för att ge gott resultat varierar, men generellt behöver neurala nätverk mycket mer data än andra modeller. Det kan påverka vilken modell som är lämplig att använda för ett givet dataset.

Maskininlärningsmodeller kan tränas på olika spatiala nivåer. Säg att vi har en uppsättning med 50 röjningsobjekt och bilder från varje enskilt objekt. Varje bild består av ett antal pixlar, säg 10 000 st. En nivå är objektsnivån, då datamängden blir $N=50$. Det är en lätthanterlig mängd men för lite data för en regressionsmodell. En annan nivå är pixelnivån. Då blir datamängden $N = 50 \times 10\,000 = 5\,000\,000$. Det är en större datamängd, men kan fortfarande vara för lite för vissa AI-modeller. Skogforsk har en metod där trädvisa skördardata klustras till halvstora områden kallade beräkningsytor. Att klustra små områden kan minska inverkan av osäkerheter i data, dock kan modellen sedan inte tillämpas på en finare spatial nivå än den som den har tränats på.

Skattning av röjningsbehov

Visuell bedömning

Svenska skogsföretag använder idag helikopterinventering över sina arealer för att kartera röjningsbehov genom visuella bedömningar. Exakta kriterier för röjningsbehov skattas olika mellan olika företag. Med tanke på det återkommande behovet av

inventering (årligen) och den stora ytan att täcka är detta väldigt ineffektivt och utförs inte alltid vilket får effekten att färre skogar röjs.

Satellitbaserad skattning

Skogsstyrelsen har använt vegetationsindex från satellitdata (en tidpunkt) för att identifiera röjningsbehov i utförda avverkningar (5–15 år efter avverkning). I Götaland indikerade den satellitbaserade metoden i större röjningsbehov än den manuella referensbedömningen till följd av områden med mycket markvegetation (gräs/ormbunkar).

Olsson (1994) utvärderade röjningar baserat på satellitdata från Landsat TM (spatial upplösning 30 x 30 m) från åtta somrar. Området hade tall, gran och björk. Regressionsmodeller baserat på bilderna kunde förklara 50 procent av variansen i röjningsgrad, uttag av grundyta eller uttag av stamvolym. Røjda ytor kunde bäst skiljas från orøjda ytor i banden TM5 (centrumvåglängd 1,6 µm), TM7 (2,2 µm), och TM3 (0,66 µm).

Persson & Bank (1998) försökte uppskatta lövrøjningsbehov baserat på satellitdata från SPOT3-satelliten (20 x 20 m) i ett projekt initierat av Skogsstyrelsen. De använde ytor som hade minst 0,28 ha i areal. Målet var att identifiera ytor med antingen akut röjningsbehov eller röjningsbehov inom fem år. Analysen baserades på en förändringsbild före och efter röjning, en skogsmask för att exkludera andra typer av marker, ett hyggeskikt för att identifiera områden med ungskog, beräkning av vegetationsindex, samt en intensitetströskling för att identifiera lövträd. Metodens träffprocent var 61–95 procent beroende på region och skogens åldersprofil. Författarna kommenterade att hyggesvegetationen (gräs, ormbunkar, etc.) och andelen blottad mineraljord gav större utslag i resultatet än andelen kvarvarande träd. Detta var framför allt ett problem i södra Sverige, medan resultaten var bättre för norra delen av landet. Författarna kommenterade vidare att en metod bör ha en träffprocent på minst 75 procent för att vara operativt användbar.

Trybom (2000) använde satellitbaserad förändringsanalys för att prediktera röjningsbehov samt identifiera om röjning hade skett. Analysen gjordes på multispektrala bilder från två olika satelliter: SPOT4 (20 x 20 m) och IRS-1C (23 x 23 m). En sensommarbild från 1997 respektive 1999 användes för att framställa en förändringsbild. Från förändringsbilden beräknades vegetationsindexet IPVI (Infrared Percentage Vegetation Index). Genom tröskling av detta index klassades ungskogsobjektet i en av följande klasser: 1) inget lövrøjningsbehov, 2) troligen inget lövrøjningsbehov, 3) osäkert, 4) lövrøjningsbehov. Metoden utvärderades enbart kvalitativt och ansågs ge relativt goda resultat. Det infraröda satellitbandet ansågs bidra mer än det röda för att identifiera tillväxt av löv.

Dahl (2001) använde raster från SPOT4-satelliten för att prediktera behov av ungskogsrøjning. Klassificering skedde på hela ytor i röjningsbehov eller ej röjningsbehov. NDVI beräknades och trösklades med ett generellt och ett anpassat värde. 73–75 procent av ytorna klassades rätt. Lägre förekomst av löv ledde till sämre klassificering än högre förekomst av löv.

Pettersson (2005) använde också data från SPOT4-satelliten för att prediktera behov av lövrøjning i ungskog. Två klasser – röjningsbehov eller icke röjningsbehov – skattades genom att beräkna och tröskla bildernas NDVI-index. En variant av Nationella Marktäckedata användes för att skilja mellan produktiv skogsmark och annan mark.

Vidare beräknades arealen med röjningsbehov för varje objekt. Validering skedde genom manuell inventering på objektsnivå. Den genomsnittliga träffsäkerheten var 77 procent, där objekt större än 1,5 ha hade högre träffsäkerhet och mindre objekt lägre träffsäkerhet.

Drönarbaserad skattning

Fransson (2014) använde drönare och manuell bildtolkning för att bedöma röjningsbehov hos ungskog. Drönaren flögs på 6–8 meters höjd, vilket gav en spatial upplösning på 2–6 pixlar/cm. Stamantal, röjningsbehov och tidsåtgång för röjning skattades, och röjningsuppföljning gjordes. Metoden hade 80 procent träffsäkerhet för antalet stammar i objektet innan röjning och 60 procent träffsäkerhet för antalet kvarvarande stammar efter röjning.

LiDAR-baserad skattning och kombinationsmetoder

Watt m.fl. (2013) använde flygburen LiDAR för att bedöma röjningsbehov hos 9–17 år gamla bestånd av Douglasträd. Röjningsbeslut fattades när stammarna hade genomsnittlig maxhöjd ≥ 14 m and och kronhöjd ≥ 3 m. Baserat på LiDAR-data gjordes multipla regressionsmodeller i SAS av genomsnittlig topphöjd, grönkrongräns, stamvolym, grundyta, DBH och densitet. Bortsett från densitet hade modellerna $R^2 > 0,8$.

Hyvönen (2002) kombinerade satellitdata (Landsat TM, 30 x 30 m) och LiDAR för att prediktera om objekt hade röjningsbehov de närmaste 10 åren eller ej. Med LiDAR bedömdes 64 procent av bestånden korrekt. När satellitdata adderades förbättrades klassificeringen till 72 procent.

Sammanfattning av litteraturen

De satellitbaserade metoderna är inriktade på lövröjning, det vill säga önskan att röja bort lövträd men behålla barrträd samt hypotesen att ett stort inslag av löv i ungskog korrelerar med högt röjningsbehov. De flesta satellitbaserade studierna använde förändringsanalys, det vill säga skillnaden mellan två eller flera bilder (tidpunkter). Ingen av de genomgångna studierna använde sig dock av mer än en förändringsbild. Ofta beräknades olika vegetationsindex från bilderna, exempelvis NDVI (Normalized Difference Vegetation Index) eller IPVI (Infrared Percentage Vegetation Index). Generella utmaningar var att hitta bilder utan moln, snö (då vår- eller vintervinterbilder användes) och bildartefakter, samt att de tillgängliga satelliterna hade relativt grov upplösning.

Drönarbaserade metoder har nackdelen att datainsamlingen är tidskrävande och i dagsläget beroende av en närvarande operatör, vilket driver upp kostnaderna. Datamängderna blir också stora. Slutsatsen av de LiDAR-baserade studierna är att trädhöjd ensamt inte är tillräckligt för att prediktera röjningsbehov, kanske för att den använda laserskanningstekniken inte kan skilja mellan löv- och barrträd.

Vidare hade majoriteten av studierna inte några detaljerade fältdata (exempelvis på pixelnivå) att validera mot, utan valideringen skedde på hela ungsogsobjekt.

Ingen av de genomgångna studierna använde AI-metoder som neurala nätverk för att prediktera röjningsbehov. Vissa studier använde klassiska statistiska metoder som PLS (Partial Least Squares).

Syfte och målbild

Projektet syftade till att undersöka hur fjärranalysdata och AI kan användas för att på ett resurseffektivt och storskaligt sätt skatta röjningsbehovet på beståndsnivå över stora områden.

Projektets mål var därför att ta fram en AI-modell baserad på multispektral satellitdata och högupplöst referensdata från fältet för att skatta röjningsbehov i olika geografiska regioner. Projektet skulle även förbereda för implementering av modellen för operativ användning.

Projektet förväntas bidra till följande långsiktiga effekter:

- Ökad röjningsaktivitet baserat på bättre möjligheter att kommunicera röjningsbehov till markägare. Detta bidrar till ökad skogsproduktion och högre värden för skogsägare.
- Effektivare röjningsplanering genom heltäckande karteringar
- Effektivare röjning genom bättre underlag för att beräkna tidsåtgång och budget

Material

Det material som beskrivs i följande avsnitt består av röjningsobjekt, avverkningsår, röjningskoordinater och tid, röjsågens varvtal, multispektral satellitdata och övriga rasterprodukter som trädhöjd och marktäckesklasser. Förbehandling av enskilda datakällor som inte kräver ytterligare datakällor utöver objektspolygonen beskrivs också i detta avsnitt.

Röjningsobjekt

Tränings- och valideringsobjekt

Tre skogsföretag – Södra, Mellanskog och Sveaskog – deltog i projektet. Företagen tillhandahöll varsin lista över objekt som skulle röjas men ännu inte hade röjts. I objektslistan fanns både ungskogsröjning, plantröjning och underväxtröjning, vilket gjorde att de senare behövde filtreras så att enbart ungskogsobjekt kvarstod. De röjningsobjekt som de tre företagens bidrog med till studien visas i Figur 2.




Figur 2. Röjningsobjekt i studien tillhörande Södra (gula), Mellanskog (rosa) respektive Sveaskog (brandgula).


De tre medverkande skogsföretagen valde sedan ut och samordnade varsitt arbetslag som samlade in följande data till projektet:

- Tidsåtgång för röjning; både total tidsåtgång för objektet och fördelning av tidsåtgång inom objektet. Detta gjordes genom insamling av GNSS-punkter från mobiltelefon från röjare inom respektive arbetslag
- Dokumentation av beståndsdata. En ansvarig person per arbetslag har samlat in denna information per röjningsobjekt
- Varvtal för röjsågar (se beskrivning senare i avsnittet)


Data samlades in under två röjningssäsonger: 2020 och 2021. En sammanställning av insamlade beståndsdata visas i Figur 3 till Figur 14. Notera att inte alla objekt har beståndsdata.




Figur 3. Trädslagsfördelning hos Södras objekt, bedömd av arbetslaget.




Figur 4. Medelhöjd hos Södras objekt, bedömd av arbetslaget.




Figur 5. Histogram över areal (ha) hos Södras objekt, baserat på objektspolygonen.




Figur 6. Histogram över diverse beståndsinformation hos Södras objekt, baserat på bedömningar från arbetslaget. Övre vänster: åldersfördelning. Övre höger: ståndortsindex (SI). Mellersta vänster: medeldiameter. Mellersta höger: stamantal. Nedre vänster: om objektet tidigare varit rött. Nedre höger: blockighet.




Figur 7. Trädslagsfördelning hos Mellanskogs objekt, bedömd av arbetslaget.




Figur 8. Medelhöjd hos Mellanskogs objekt, bedömd av arbetslaget.



Figur 9. Histogram över areal (ha) hos Mellanskogs objekt, baserat på objektspolygonen.




Figur 10. Histogram över diverse beståndsinformation hos Mellanskogs objekt, baserat på bedömningar från arbetslaget. Övre vänster: åldersfördelning. Övre höger: ståndortsindex (SI). Mellersta vänster: medeldiameter. Mellersta höger: stamantal. Nedre vänster: om objektet tidigare varit röjt. Nedre höger: blockighet.




Figur 11. Trädslagsfördelning hos Sveaskogs objekt, bedömd av arbetslaget.



Figur 12. Medelhöjd hos Sveaskogs objekt, bedömd av arbetslaget.



Figur 13. Histogram över areal (ha) hos Sveaskogs objekt, baserat på objektpolygonen.



Figur 14. Histogram över beståndsinformation hos Sveaskogs objekt, baserat på bedömningar från arbetslaget. Övre vänster: åldersfördelning. Övre höger: ståndortsindex (SI). Mellersta vänster: medeldiameter. Mellersta höger: stamantal. Nedre vänster: om objektet tidigare varit röjt. Nedre höger: blockighet.

Beståndsdata visar att förhållande i röjningsobjekten skiljer sig åt mellan södra och norra Sverige, vilket kan skapa ett behov av olika modeller för olika geografier.


Vid utvecklingen av modellen delades röjningsobjekten upp i ett tränings-dataset och ett validerings-dataset.



Figur 15. Exempelbilder på röjningsobjekt i studien.

Demonstrationsobjekt

Under projektets slutfas valdes 13 objekt ut av Södra för validering av modellens resultat i fält, med målet att demonstrera såväl variationen i röjningsbehov inom ett röjningsobjekt som variationen mellan objekt. För att göra en meningsfull utvärdering krävdes att objekten för tidpunkten var planerade för röjning, dvs att det fanns ett känt röjningsbehov, samt samordning kring att ingen röjning blivit utförd på objekten under tiden modellen applicerades på objekten och att fältdemonstrationen ägde rum.




Figur 16. Översiktskarta för Södras demonstrationsobjekt

Avverkningsår

Skogsstyrelsen erbjuder ett vektorskikt kallat *Utförda avverkningar* där avverkningsår för en stor andel objekt avverkade de senaste 20 åren finns med (Skogsstyrelsen 2022). Ett exempel visas i Figur 17. Detektionen av nya avverkade objekt sker via en satellitbaserad metod, därav missas vissa objekt.

Vektorskiktet *Utförda avverkningar* hämtades för samtliga de regioner där röjningsobjekten fanns och användes för att exkludera röjningsobjekt av plantröjnings- eller underväxtröjningskaraktär utifrån deras avverkningsår, då skogen antogs kunna vara så pass annorlunda jämfört med ungskogsröjning att det skulle påverka röjningsskattningens noggrannhet.




Figur 17. Exempel på matchning av röjningsobjekt med geodatatjänsten Utförda avverkningar. Okänt år innebär att objektet inte fanns med i Utförda avverkningar.

Röjningskoordinater och tid

Insamling

Varje röjare i ett arbetslag per skogsföretag utrustades med mobiltelefoner med en app installerad för att spåra GNSS-punkter under pågående röjningar.

Appen som användes för att spåra GNSS-punkter var "GPS Logger" av utvecklaren "Mendhak". Instruktioner om handhavande av appen som gick ut till röjare bifogas i Appendix B. Mjukvaran ställdes in för att logga GNSS-punkter var 10:e sekund så länge appen var aktiverad. I praktiken blev loggningsfrekvensen något lägre, med en mediantid på 12 sekunder mellan två GNSS-punkter. GNSS-positioneringens osäkerhet bedömdes vara ca 5 m. GNSS-loggarna sparades då också automatiskt på en FTP-server var 60:e min. Arbetssätten mellan olika röjare skiljde sig åt något. En del startade appen aktivt under pågående röjning och stängde av den vid avslutad röjning, medan andra lät appen vara aktiv hela tiden när telefonen var påslagen. Figur 18 visar ett exempel på GNSS-koordinater från tre objekt.



Figur 18. Exempel på GNSS-koordinater från tre röjningsobjekt, färglagda efter individuell röjare. Röjningsobjektens gränser visas som lila polygoner.

I appen tilldelades varje telefon ett unikt ID som följde med telefonens GNSS-loggar. Varje telefon-ID kopplades till den röjsåg som röjaren med aktuell telefon bar med sig. På så sätt kunde information om varvtal analyseras tillsammans med GNSS-loggar.

Tabell 2: Telefoner för datainsamling.

Företag	Antal telefoner som användes för insamling av GNSS-loggar
Södra	8
Mellanskog	7
Sveaskog	5

GDPR


Insamlingen av fältdata tjänade ett specifikt syfte: att skapa en fältreferens för att bedöma röjningsbehovets omfattning. Det är viktigt att dessa data inte används för att utvärdera röjarnas individuella prestationer. Telefon-ID och data från röjsågarna sparades aldrig tillsammans med personuppgifter, namn eller annan information kopplad till enskilda personer. Under efterbearbetningen av GNSS-loggarna sparades endast GNSS-punkter inom och intill aktuella röjningsobjekt. GNSS- och röjsågsdata var endast tillgängligt för medlemmar i arbetsgruppen och delades ej med skogsföretagen.

Filtrering av ungskogsröjningsobjekt

Av de extensiva listorna på röjningsobjekt från varje skogsföretag röjdes endast ett mindre antal av arbetslaget utrustat med appen GPS-logger. För att identifiera de relevanta objekten klipptes GNSS-data med objektens geometri, efter att geometrin expanderats med 30 meter. Varje objekt inspekterades sedan manuellt och jämfördes med kompletterande ortofoton och avverkningsår för att bedöma om den utförda röjningen varit ungskogsröjning, plantröjning eller underväxtröjning. Information om avverkningsår fanns endast tillgängligt tjugo år bakåt, det vill säga efter 1999. Om avverkningsår var mindre än tre år innan utförd röjning och ortofotot var av

hyggeskaraktär bedömdes objektet som plantröjning. Om ortofotot hade karaktären av mogen skog bedömdes objektet som underväxtröjning. Om avverkningsåret var fem till tjugofem år tidigare och ortofotot hade ungskogskaraktär bedömdes objektet som ungskogsröjning. Ungskogsobjekt med lång tid sedan avverkning förekom främst i Norrland, vilket kan förklaras med långsammare tillväxt. Vissa sådana objekt förekom även i södra och mellersta Sverige, vilket förklaras av eftersatt röjning. Slutligen exkluderades några objekt av oklar röjningstyp, samt några ungskogsobjekt där över 25 år gått sedan avverkning.

Ungskogsobjekten bedömdes sedan utifrån datas fullständighet. I vissa objekt var det tydligt att GNSS-data från en eller två röjare saknades, då gångmönstren var inkompleta. Sådana objekt exkluderades. I andra objekt var det oklart om GNSS-data saknades eller ej, särskilt i norra Sverige. Där gjordes bedömning från fall till fall.



Figur 19. Övre vänster: objekt i södra Sverige med rapporterad saknad GNSS-data från två telefoner. Övre höger: svårbedömt objekt i södra Sverige som ansågs vara komplett. Nedre vänster och höger: svårbedömda objekt i norra Sverige som bedömdes vara kompletta.


Totalt behövs 274 ungskogsobjekt med tillhörande GNSS-data, se Tabell 3. Varje sådant objekt tilldelades ett objekts-ID och GNSS-data inuti objektet markerades med samma ID.

Tabell 3. Antal röjningsobjekt av ungskogskaraktär med GNSS-data efter filtrering och kvalitetskontroll.

År	Södra	Mellanskog	Sveaskog
2020	34	24	32
2021	75	52	57
Totalt	109	76	89

Omsampling

Röjningskoordinaterna loggades med ett medianintervall, F , om 12 sekunder mellan två punkter (0,083 Hz). För att skapa en jämnare spatial fördelning av punkterna omsamlades frekvensen till 1 Hz genom att addera punkter till koordinatdata, se Figur 20 (vänstra). För varje objekt expanderades först dess polygon med 30 m för att buffra för effekten som uppstår då röjare går utanför objektets gränser och sedan in igen. Därefter klipptes koordinatdata till det aktuella objektet för att skapa en hanterlig datamängd. För varje par om två punkter beräknades avståndet och tidsdifferensen. Om avståndet var större än 50 m eller tidsdifferensen större än 300 s ignorerades punkten. Detta kan till exempel inträffa när röjarna har befunnit sig nära objektets gräns och röjarna har gått ut på en angränsande väg och sedan gått tillbaka in i objektet längre fram. Om punkterna klarade kriterierna placerades ($F - 1$) punkter ut i en rak linje mellan de två originalpunkterna, se Figur 20 (högra). Slutligen klipptes koordinatpunkterna igen, denna gång med objektets polygon minskad (eroderad) med 10 meter. Detta gjordes för att minska kant- och GNSS-osäkerhetseffekter.



Figur 20. Vänster: Illustrationer av omsampling av två punkter P1 och P2 från 12 sekunder mellan två punkter till 1 sekund mellan två punkter. De röda punkterna är originalpunkterna medan de gula är de tillagda punkterna. Höger: Exempel från ett verkligt objekt. Siffrorna är punktens index. Den blå linjen är en objektsgräns som passerades under röjningen.

Röjsågsdata

Introduktion

Röjningstid- och koordinater ger värdefull information om röjarens förflyttning men inte om vad som har skett under förflyttningen. Om två röjare har stannat inom en mindre yta


i tio minuter kan det antingen bero på att området var svåröjt eller att de hade fikapaus. För att få ett mått på kvalitén i tids- och koordinatinformationen utrustades arbetslagen med sågar utlånade av Husqvarna och försedda med maskinsensorn Husqvarna Fleet Services (Husqvarna 2023), se Figur 21.



Figur 21. Vänster: Husqvarna Fleet Services-sensor. Höger: Husqvarna röjsåg.

Beskrivning

De datatyper som loggades av sensorn visas i Tabell 4. Noterbart är att Fleet-sensorn loggade tid men inte koordinater. Det gick därför inte att använda sensorn som enda datakälla i projektet. Data lagrades lokalt i sensorn i block som kallades sessioner. En session skapades var 15:e minut eller när motorn stängdes av. När motorn var avstängd registrerades ingen information. Informationen behövde sedan synkas med Husqvarnas molnbaserade Fleet-databas. Om ingen synkning skett på tre månader skrevs den äldsta lokala informationen över. Tillgängliga data kunde hämtas som csv-filer via Husqvarna Fleet Services dashboard (Figur 22, Figur 23 och Figur A. 9).



Figur 22. Exempel på brukarstatistik från Husqvarna Fleet Services dashboard.




Figur 23. Exempel på graf över maskin användningsnyttjande från Husqvarna Fleet Services dashboard.

Den viktigaste informationen som tillhandahålls är antalet sekunder under sessionen då motorns varvtal tilldelades en av de fyra klasserna tomgång (idle mode), låg (low mode), optimal (optimal mode) eller hög (high mode). Klassen beräknas baserat på varvtalshistogrammet var hundra rotation per sekund (rps). Om motorn är avstängd eller i tomgångsläge indikerar detta att den inte används för röjning. Ett exempel på fördelningen i tid mellan de olika lägena för ett enskilt objekt visas i Figur 24.

Tabell 4. Fält i logfilen till Husqvarna Fleet-sensorn. Notera att sensorn inte ger koordinater.

Fält	Beskrivning
asset id	System-id för sågen, exv. b1749f09-044d-4c6f-8c65-9a63ed16586a
asset name	Egenvalt såg-id, exv. "LG6"
session start	YYYY-MM-DD HH:MM Z
session stop	YYYY-MM-DD HH:MM Z
Duration	Sessionslängd i sekunder
time idle mode	Antalet sekunder i tomgångsläge under session
time low mode	Antalet sekunder i låg varvtalsklass under session
time optimal mode	Antalet sekunder i optimal varvtalsklass under session
time high mode	Antalet sekunder i hög varvtalsklass under session



Figur 24. Andel av sin arbetstid som varje röjare använde röjsågen i en given varvtalsklass (förutom Low mode, som ingen använde). En stapel representerar en röjare. Överst: High mode. Mitten: Optimal mode. Nederst: Idle mode (tomgång).

Datainsamling röjsågsdata

I södra Sverige användes sju sensorutrustade röjsågar, varav en byttes ut under tiden. I Mellansverige utrustades sju sågar, som dock inte kom att användas. I norra Sverige användes fem sågar, varav en byttes ut under tiden. För varje region försågs en arbetsledare med en Fleet-app för synkning av data. Arbetsledaren behövde regelbundet möta arbetslagen för att synka sensorernas lokala data till Fleet-databasen. Tidsdata gavs i formatet Coordinated Universal Time (UTC), vilken inte beaktar sommartid och ligger en timme före svensk tid. Inför matchning med GNSS-data omvandlades röjsågsdata därför till svensk tid, inklusive sommartidskompensation.

Röjsågens namn anonymiserades så att vilken arbetare som använt vilken röjsåg endast var känt för Skogforsks och Fields personal. En utmaning var att säkerställa att samma GNSS-loggande telefon alltid användes med samma röjsåg, så att deras respektive information gick att matcha. Under projektets gång påtalades det att vissa röjare ibland tejpade fast sågen i high mode, vilket gjorde kvalitetskontroll av andelen tid i olika modes extra viktig. Det visade sig även att ingen röjare arbetade i varvtalsklassen "low mode".

Matchning av röjsågsdata och GNSS-koordinater

Röjsågsdata och GNSS-koordinater matchades baserat på kopplingen mellan telefon-id och röjsågs-id samt tidsstämpel. Varje sekund i det omsamlade koordinatdatat matchades mot den närmaste tidsstämpeln i röjsågsdata. På grund av den stora skillnaden i samplingsfrekvens, 1 Hz för koordinaterna jämfört med upp mot 0,001 Hz för röjsågsdata, fick många koordinater identiska värden för maskindata.

I slutändan inkom komplett röjningsdata för så få objekt att det inte var praktiskt möjligt att nyttja data för att förfinas skattningen av röjningsbehov, se Tabell 5.

Tabell 5. Statistik över insamlad röjsågsdata 2020-2021 för regionen södra Sverige. Ett objekt ansågs vara partiellt om maskindata för endast en röjare samlades in för det givna objektet.

	2020	2021	Totalt
Komplett objekt	22	11	33
Partiella objekt	9	42	51
Saknade objekt	4	26	30

Multispektrala satellitdata

Beskrivning

Europeiska Rymdstyrelsen ESA:s två satelliter Sentinel-2A och Sentinel-2B passerar över Sverige ungefär vartannat dygn. Data har tolv band som beskrivs i Tabell 6. Valfritt antal band kan hämtas. Skogsstyrelsen tillhandahåller kostnadsfritt bearbetade multispektrala satellitdata från Sentinel-2 (Skogsstyrelsen 2020c). Tjänsten lanserades ursprungligen under namnet SWEA. Skogsstyrelsen hämtar level 2A-bilder från Copernicus Data and Information Access Service (DIAS) via plattformen Mundi Web Services (Persson 2019; Skogsstyrelsen 2020c). Level 2A innebär att bilderna är kompenserade för atmosfäriska störningar och att bildvärdena består av ytans reflektans. Dataflödet är baserat på ESRI Mosaic Dataset Configuration Script (MDCS) och lagras på en ArcGIS-server. Vid denna period hade Skogsstyrelsen som rutin att inte hämta Sentinel-2 bilder från ESA under månaderna november, december, januari och februari på grund av den höga molnfrekvensen i Sverige. För övriga månader laddas bilderna först ner till en mosaikdatauppsättning med tiles på 110×110 km. Data omvandlas till en virtuell datauppsättning, som är anpassad till det nationella rutnätets 100×100 km tiles. Bearbetningsprocessen slår samman alla spatiala överlappningar mellan ursprungliga tiles och projicerar data till SWEREF99-koordinater. De band som har grövre upplösning än 10 m omsamlas till upplösningen 10 m med bilinjär interpolering (Anders Persson, Skogsstyrelsen, pers. kom. 2023). Pixeldjupet i bilderna är 16 bitar, det vill säga värden mellan 0 och 65535 förekommer.

Bilderna från den virtuella datamängden laddas sedan ner efter användarens önskemål, givet hörnkoordinater för en begränsningsrektangel och en maximal bildstorlek på $15\,000 \times 15\,000$ pixlar. Standardbildstorleken är 400×400 pixlar. En spatial omsampling utförs automatiskt baserat på den användargivna begränsningsrutan och bildstorleken. Standardmetoden för omsampling till begärd bildstorlek är Nearest Neighbour.

Tabell 6. Rasterband i Sentinel-2 data från Skogsstyrelsen samt kategorier och färgklassning hos Scene Classification Layer (SCL).

Band	Beskrivning	Spatial upplösning [m]
B2	Blue	10
B3	Green	10
B4	Red	10
B8	NIR	10
B5	Red Edge 1	20
B6	Red Edge 2	20
B7	Red Edge 3	20
B8A	Red Edge 4	20
B11	SWIR1	20
B12	SWIR2	20
B1	Coastal	60
B9	Water vapor	60
SCL	Scene Classification Layer	20

Datainsamling multispektrala satellitdata

I detta projekt hämtades bilder från Skogsstyrelsens tjänst via ett REST API-anrop implementerat i Python. Nyckelpaket i Python var requests, geopandas, imagecodecs och rioarray. Indata var polygoner (vektordata) över alla röjningsobjekt inom en region. Målsättningen var att få lokala Sentinel-2 raster med spatial upplösning $10 \times 10 \text{ m}^2$ över vart och ett av objekten. REST API-anropet krävde hörnkoordinater för objektets begränsningsruta samt önskad bildstorlek.

Polygonerna laddades in via Python-paketet geopandas och minskades (eroderades) med 10 meter för att inkludera GNSS-positioneringsosäkerheten och mildra kanteffekter. För varje polygon extraherades sedan dess spatiala begränsningsruta (bounding box). Begränsningsrutan kvalitetsgranskades för att säkerställa att den var inom Sveriges gränser. Begränsningsrutan expanderades så att varje hörnkoordinat hamnade i den närmsta SWEREF99 koordinaten som var jämnt delbar med 10. Baserat på den nya begränsningsrutan och upplösningen $10 \times 10 \text{ m}^2$ beräknades den nya bildstorleken i längs- och höjddled.


Bildhämtningen skedde sedan i två led. Det första anropet gav ett objekt-id till Skogsstyrelsens databas. Detta objekt-id infogades sedan tillsammans med specifikation på bildtekniska parametrar i ett andra anrop. I detta projekt användes bildformatet tiff och förlustfri LZ77-komprimering. Det andra anropet resulterade i en sträng i byte-format som avkodades till en bild med Python-paketet imagecodecs. Det kan noteras att bilden ibland var en pixel större eller mindre än storleken som önskats i anropet. Då bilden inte var geokodad behövde den koordinatsättas. Centrumkoordinaterna för varje pixel beräknades baserat på begränsningsrutan och den spatiala upplösningen och infogades till en geokodad bild via paketet rioarray. Samma paket användes sedan för att spara bilden lokalt.

Tidsserie och filtrering av molniga bilder

För att få material till maskininlärningen önskades så många bilder som möjligt för varje månad och år. För varje datum kan ett eller flera av följande kvalitetsproblem förekomma:

1. Satelliten passerade ej (ingen bild alls)
2. Molnförekomst
3. Mättnad (helvit bild)
4. Tom (helsvart bild)
5. Artefakter på grund av sensor- eller ljusstörningar

För att hantera detta gjordes en förkontroll innan den skarpa hämtningen, med fokus på kvalitetsproblemen #2-#4. För ett givet datum gjordes det första anropet. Om inget objekt-id skickades (kvalitetsproblem #1) ändrades datumet till föregående dag och anropet repeterades tills ett datum med ett objekt-id identifierades. Via det andra anropet hämtades objektets Scene Classification Layer (SCL, band 12), vars klasser visas i Figur 25.



Figur 25. Vänster: exempel på Scene Classification Layer (SCL) för ett röjningsobjekt. Höger: värden och förklaring för färgkodningen i SCL.

Om andelen pixlar med kategori A (No data) var högre än 20 procent av totala antalet pixlar kastades bilden och närmast föregående datum prövades i stället. Om bilden klarade kriteriet beräknades ett molnighetsdominerat kvalitetsmått enligt:


$$M = 100 \cdot \frac{\sum_{\text{kategori B}} \text{Antal pixlar}}{\sum_{\text{kategori B+C}} \text{Antal pixlar}}$$

Måttet beaktar endast de lokala förhållandena över själva röjningsobjektet. Det betyder att två närbelägna objekt kan få olika kvalitetsbedömning om det ena objektet var molnigt den aktuella dagen medan grannobjektet hade klart väder.

Tabell 7. Klasser i Sentinel-2s Scene Classification Layer (SCL). Klasserna delas här in i tre kategorier, A: saknade data, B: kvalitetssänkande klass, C: standardklass.

Klassnamn	Förklaring	Kategori
No data	Data saknas	A
Saturated/defective	Mättad eller defekt	B
Topografiska skuggor	Skuggor från exv. berg	B
Cloud shadows	Molnshadowor	B
Vegetation	Växtlighet	C
Not-vegetated	Utan växtlighet, till exempel vägar eller tak	C
Water	Vatten	C
Unclassified	Oklassificerad	B
Cloud medium probability	Molnigt med måttlig sannolikhet	B
Cloud high probability	Molnigt med hög sannolikhet	B
Thin cirrus	Molnslöjor	B
Snow or ice	Snö eller is	B

Om värdet på kvalitetsmättet var högre än 5 procent förkastades det aktuella datumet och processen repeterades för föregående datum, tills ett datum med acceptabel kvalitet hittades. Då hämtades och sparades alla band enligt beskrivningen ovan. Därefter gjordes ytterligare en validering då Scene Classification Layer, och därför också kvalitetsmättet, ofta missade optiska artefakter samt vissa molnslöjor, se Figur 26.



Figur 26. Exempel på värden på kvalitetsmättet. Vänster: 0 procent moln. Mitt: 4 procent moln, men även viss optisk artefakt. Höger: 0 procent moln, men kraftig optisk artefakt.

Z-score, ett mått på varians, beräknades för varje enskilt band enligt Ekvation 1:

$$z = \frac{P - \text{mean}(P)}{\text{std}(P)} \quad \text{Ekv. [1]}$$

där P är bildens pixelmatris. Om bildens genomsnittliga z-score, var större än tre filterades bilden bort. Bilderna hämtades för år 2020, det vill säga innan rönjning, och från månaden juli, då hela Sverige bör ha grönt lövverk. För de 109 objekten i södra Sverige återstod totalt 403 bilder efter filtrering, se Tabell 8.

Tabell 8. Antal Sentinel-2 bilder som användes för träning och validering av AI-modellen, hämtade via Skogsstyrelsen för regionen södra Sverige.


År	Träning	Validering	Totalt
2020, juli månad	357	46	403

Bivariabler

Fyra ytterligare rasterdatakällor användes: märktäckeklass (NMD), markfuktighet, lutning, och trädhöjd (Figur 27). Dessa kallas gemensamt för bivariabler. Dessa data uppdateras med några års mellanrum, vanligen när en ny nationell laserskanning skett. Exempelvis trädhöjdskartan kan med andra ord vara några år gammal och därmed ge viss underskattning av trädhöjderna.

Samtliga bivariabler hämtades från Skogsstyrelsens REST-API:er på liknande sätt som för Sentinel-2 och omsamplades vid nedladdning till 10 × 10 m upplösning med Nearest-Neighbour interpolering.

Bilderna från Sentinel-2 och bivariabler slogs samman till en bildkub med 12 band. För ytterligare filtrering av outliers togs pixlar med z-score större än tre bort. Slutligen normaliserades varje band till att ha pixelvärden mellan noll och ett, då detta krävdes av den valda maskininlärningsmodellen.



Figur 27. Exempel på övriga kartprodukter. Vänster-vänster: objektpolygon (gul) med bakgrund av ortofoto. Vänster: nationella marktäckedata (NMD). Mitt: markfukt. Höger: höjdmodell. Höger-höger: lutning.

Marktäckeklass

Marktäckeklass, eller nationella marktäckedata (NMD) är en klassning av hela Sveriges marktäckte baserat på satellitbilder och laserdata (Naturvårdsverket 2020). Den bedömda noggrannheten är 74 procent på områden större än 1 ha. Exempel på klasstyper- och värden visas i Tabell 9. Produkten laddas ner som ett raster med standardupplösningen 10 × 10 m. I den aktuella studien användes NMD dels för att filtrera bort vägar och andra hårdgjorda ytor, dels som en ren träningsparameter (feature).

Tabell 9. Klasser i nationella marktäckedata relevanta för den aktuella studien.

Klassvärde	Beskrivning
111	Tallskog utanför våtmark
112	Granskog utanför våtmark
113	Blandad barrskog utanför våtmark
114	Blandskog utanför våtmark
115	Lövskog utanför våtmark
116	Ädellövskog utanför våtmark
117	Lövskog med inslag av ädellöv utanför våtmark
118	Tillfällig icke-skog utanför våtmark
121	Tallskog på våtmark
122	Granskog på våtmark
123	Blandad barrskog på våtmark
124	Blandskog på våtmark
125	Lövskog på våtmark
126	Ädellövskog på våtmark
127	Lövskog med inslag av ädellöv på våtmark
128	Tillfällig icke-skog på våtmark
2	Öppen våtmark
3	Jordbruksmark
41	Öppen bark, ej bevuxen
42	Bevuxen öppen mark
51	Artificiell yta, byggnad
52	Artificiell yta, ej byggnad eller väg/järnväg
53	Artificiell yta, väg/järnväg
61	Sötvatten
62	Saltvatten
0	Utanför karteringsområdet

Markfuktighetskartan (DTW)

En hög markfuktighet kan indikera svårare röjningsförhållanden eller förhållanden som gynnar lövsly. Båda dessa faktorer gör att röjningen tar längre tid. Markfuktighetskartan motsvarar det topografiska måttet Depth-to-Water (DTW) och innehåller modellerat avstånd till grundvattenytan i centimeter (Skogsstyrelsen 2020b). Rastret har en upplösning om $2,0 \times 2,0 \text{ m}^2$ och värden 0–65535. Ett möjligt alternativt raster är SLU:s produkt Markfuktighet, som även inkorporerar Soil Wetness Index och anger sannolikheten för att en pixel är fuktig på en skala mellan 0-100 procent (Ågren m.fl. 2021).

Trädhöjd

Trädhöjd är bland annat användbar för att filtrera bort vuxna träd ur satellitdata. Trädhöjdskartan visar trädhöjd i enheten decimeter och med upplösningen $2,0 \times 2,0 \text{ m}^2$ (Skogsstyrelsen 2020d). Pixlar som saknar träd, har träd lägre än 1 meter eller saknar matchade bildpunkter får bildvärde noll. Ett träd kan bestå av flera pixlar. Möjliga alternativa raster är grundytevägd medelhöjd (hgv) eller p95 (övre höjd) från Skogliga grunddata.

Lutning

En hög lutning kan indikera svårtröjda förhållanden, vilket gör att röjningen tar längre tid. Lutningskartan ger terrängens lutning i grader, baserat på Lantmäteriets digitala höjdmodell (Skogsstyrelsen 2020a). Upplösningen är $2,0 \times 2,0 \text{ m}^2$.

Metoder


Hypotes

Modellen grundar sig på två hypoteser. Den ena hypotesen är att röjningsbehovet i ett område korrelerar med den tid som varje röjare spenderar i området. Det förutsätter att röjningstiden korrelerar med terrängrelaterade och röjningsrelaterade faktorer som markfuktighet, lutning, stamantal, och stamdensitet. Den andra hypotesen är att röjningsbehovet korrelerar med mått som kan detekteras i multispektrala satellitbilder, vilket litteraturgenomgången tyder på. Bland annat visar litteraturen att förekomsten av lövträd kan skiljas från förekomst av barrträd, och hög förekomst av löv inom ett ungskogsobjekt tyder på högt röjningsbehov. Modellen ska försöka fånga bägge hypoteserna.

Fältreferensdata

Framtagning av färgdiagram

Framtagningen av färgdiagram (eng: heatmap) sammanfattas i Figur 28:



Figur 28. Flödesschema för framtagning av färgdiagram.

Från de omsamlade röjningskoordinaterna konstruerades färgdiagram med 10×10 meters upplösning. Detta gjordes i Python med nyckelpaketerna numpy, geopandas, rioxarray och geocube. Röjningspolygonens hörnkoordinater extraherades och flyttades till den närmsta koordinaten utanför polygonen med SWEREF99-TM koordinater jämnt

delbara med 10. Baserat på den nya begränsningsrutan konstruerades ett vektorbaserat rutnät med 10×10 meters rutor.

Rastreringen gjordes med paketet geocube och validerades med numpy-paketets 2D-histogram. I rastreringen summeras antalet punkter i varje tiometersruta och omvandlas till värden i ett raster. Därefter filterades rastret för att ta bort icke-ungskog, genom att pixlar som uppfyllde följande villkor gavs värdet NaN (Not a Number):

- Pixlar utanför röjningsobjektets expanderade polygon
- Pixlar som enligt nationella marktäckedata hade värde 53 (väg)
- Pixlar som enligt trädhöjdskartan hade värden större än $1,3 \times$ medianvärdet för varje objekt, då dessa antogs vara naturvärdesträd eller fröträdställningar

För många objekt fanns det också pixlar innanför polygonen där inga röjare hade gått, vilket gav ett värde på noll i den pixeln i färgdiagrammet. Att ingen röjare gått i en pixel kan ha flera orsaker:


1. Pixeln saknar röjningsbehov
2. Pixeln har röjningsbehov men GNSS-data saknas på grund av telefonproblem

Då det saknades praktisk möjlighet att skilja mellan dessa fall sattes båda till NaN, det vill säga okänt röjningsbehov. Det fanns även pixlar med extremt höga värden. Detta kan ha tre orsaker:


1. Röjningsbehovet var extremt högt
2. Flera röjare befann sig i samma pixel, exempelvis på genomfart till en annan del av objektet
3. Röjaren eller röjarna var stilla under lång tid, exempelvis för att ta rast

Enligt arbetslagen är det ovanligt att två röjare samarbetar för att röja samma delområde i ett objekt. Det går därför att anta att i de fall då två röjare befinner sig en längre tid i samma pixel så är det inte för att de båda arbetar. I de fall då den totala tiden i en ruta var större än 600 sekunder (10 minuter) och minst två röjare befunnit sig i samma ruta togs koordinaterna bort för den röjare som varit kortast tid i rutan. Om röjningstiden fortfarande var större än 600 sekunder trösklades den till detta värde.

Exempel på framställning av färgdiagram visas i Figur 29 och Figur 30.




Figur 29. Exempel på rastering av GNSS-koordinater till färgdiagram för ett större objekt. Vänster: Röjningsobjekt med originalpolygon (orange), rutnät och omsamlade GNSS-koordinater (gröna punkter) klippta till 10 m innanför polygonens gränser. Höger: färgdiagram framställt från koordinaterna till vänster, med färgskala som motsvarar totala tiden i varje pixel i enheten sekunder.



Figur 30. Exempel på rastering av GNSS-koordinater till färgdiagram för ett mindre objekt. Vänster: Röjningsobjekt med originalpolygon (orange), rutnät och omsamlade GNSS-koordinater (gröna punkter) klippta till 10 m innanför polygonens gränser. Höger: färgdiagram framställt från koordinaterna till vänster, med färgskala som motsvarar totala tiden i varje pixel i enheten sekunder.

Skillnaden mellan att producera färgdiagram från antalet koordinater i en pixel jämfört med att summera den totala tiden spenderad i en pixel visas i Figur 31.



Figur 31. Vänster: Objektpolygon med bakgrund av ortofoto. Mitten-vänster: koordinater från mobilappen inlagda, där olika färger representerar olika röjare. Mitten-höger: färgdiagram beräknat som antalet koordinatpunkter i varje 10 x 10 m pixel. Höger: färgdiagram beräknat som totala tidsåtgången (s) i varje 10 x 10 m pixel.

Modellering

Olika testade metoder

Projektet inleddes med en utforskande del, dels när det gällde inhämtning av rasterdata, dels när det gällde val av maskininlärningsmodell. Exempel på testade-modeller var Random Forest, Multinomial Logistic Regression, Nearest Neighbor, UNET, linjär modell och Multivariat Regression Spline. Vidare testades både regressionsmodeller (kontinuerliga värden på röjningstid) och klassificeringsmodeller i två till tre klasser, exempelvis inget röjningsbehov, lågt röjningsbehov och högt röjningsbehov. De flesta regressionsmodeller hade svårt att prediktera långa röjningstider.

Den valda regressionsmodellen, som detaljeras nedan, var mer flexibel när det gäller både att ändra i modellen och förbereda för implementering, baserat på det fullständiga datasetet.


AI-modellen

Modellen som valdes var ett neuralt nätverk (Zou m.fl. 2009; Abiodun m.fl. 2018), specifikt modelltypen Multilayer Perceptron, MPL (Tolstikhin m.fl. 2021; Zhang m.fl. 2023). Implementeringen gjordes i Python med Tensorflow-Keras.

Indata till modellen var 16 värden (features) som bestod av de normaliserade pixelvärdena från 12 band från Sentinel-2 (Tabell 6): Coastal, Blue, Green, Red, Red Edge 1, Red Edge 2, Red Edge 3, NIR, Red Edge 4, Water vapor, SWIR1, och SWIR2, samt fyra terrängvariabler: märktäckesklass, markfuktighet, lutning, och trädhöjd. Normalisering av indata skedde med L1-normalisering, det vill säga att värden över och under två standardavvikelser saturerades och normaliserades till värden mellan 0 och 1 med min-max normalisering. Modellen tränades i tabellformat, det vill säga de tvådimensionella bilderna omformades till endimensionella kolumner, med en kolumn för varje band.

Utdata från modellen var ett kontinuerligt värde som representerade den uppskattade tidsåtgången för röjning i sekunder.

Modellen sammanfattas i Figur 32. De mellersta lagren på modellen bestod av 3 dolda lager med 256, 128 och 64 neuroner med en dropout chans på 20 procent, 10 procent, och 10 procent för respektive lager. Aktiveringsfunktionen var RELU (Rectified Linear Unit) och modellen tränades med ADAM-optimizeren. Modellen hade totalt 45 569 st modellparametrar som skulle tränas.




Figur 32. Illustration av Multilayer Perceptron-modellen och dess parametrar.

Bilder från objekt där det inte fanns någon predikterad vegetation på Scene Classification Layer (SCL, Tabell 6) från Sentinel-2 togs bort från träningsdatat. Individuella träningsdata (pixlar) från varje objekt filterades bort då:

- någon av de 16 indata punkterna saknade ett värde (NaN), eller
- den verkliga röjningstiden översteg 300 sekunder

Totalt kvarstod 32 293 träningspixlar som modellen tränades på.

Validering skedde på 4 375 valideringspixlar tagna från 46 bilder från 12 olika objekt som inte var med i träningsdata. Predikterade kartor över röjningsbehovet för de 12 objekten gjordes och jämfördes med den verkliga tidsåtgången för röjning. Mean Absolute Error (MAE) användes som valideringsmått, se Figur 33.



Figur 33. Tränings- och valideringsförlust för modellen (Mean Absolute Error, sekunder).

Validering i fält


Ett fältbesök utfördes för att jämföra modellresultaten med egna observationer kring uppskattning av tidsåtgång och behov av röjning. Företaget Södra bistod projektet med cirka 10 objekt som var planerade för röjning (Figur 34-Figur 36).

Som ett första steg besökte projektdeltagare från Field dessa röjningsobjekt för att utvärdera modellen och förbereda för fältdemonstration där alla deltagare och intressenter till projektet senare bjöds in att delta.

Både den totala tidsåtgången för röjning av ett objekt och variationen av tidsåtgång inom objektet var intressanta att utvärdera. Även om objekten är likåldriga av samma trädslag är det vanligt att markfukt och lutning tillsammans med andra faktorer gör att variationen inom beståndet ändå kan vara ganska stor. Detta utgör en svårighet för modelleringen, men är också en anledning till att resultaten är användbara.

Förhoppningen med modellen är att faktorer som stamantal, lövandel och lutning (Tabell 1) ska kunna fångas upp i modellen och bidra till predikterat röjningsbehov, medan exempelvis arbetslagets erfarenhet inte modelleras i detta projekt.

Under övningen uppmanades deltagarna att besöka några olika förvalda platser runt om i två röjningsobjekt. Samtidigt fick deltagarna studera predikterad tidsåtgång för röjning i en karta och jämföra med hur de själva skulle uppskatta behov och tidsåtgång för röjning. Dessutom uppmanades deltagarna att fundera på och diskutera hur användandet av en dylik karta skulle kunna användas praktiskt. Bakgrundskartor, ortofoto, objektspolygoner och predikterade värden visades i ett fältverktyg i deltagarnas mobiltelefoner.



Figur 34. Exempel på pixelbaserad skattning av röjningsbehovet som tidsåtgång för röjning från demonstrationsobjekt.



Figur 35: Foto från demonstrationsobjekt, lövsvacka.




Figur 36: Foto från demonstrationsobjekt, till vänster talldominerat och till höger inslag av örnbräken.


Resultat

Modell av röjningsbehov

Ett exempel på modellens resultat på ett valideringsobjekt visas i Figur 37.



Figur 37. Resultatexempel #1. Vänster: Satellitbild. Mitt: Valideringsdata (färgdiagram baserat på fältdata). Höger: modellens resultat.



Figur 38. Resultatexempel #2. Vänster: Satellitbild. Mitt: Valideringsdata (färgdiagram baserat på fältdata). Höger: modellens resultat.

Medelfelet (mean absolute error, MAE) för modellen per pixel var 56,1 sekunder på valideringsdata, vilket betyder att modellen kan prediktera rätt tidsåtgång på nya data med i genomsnitt ett fel på omkring en minut i varje 10×10 m pixel. På objektsnivå var underestimeringen av röjningstiden på 58 procent. Baserat på erfarenheter från demonstrationen kan modellen ranka objekt efter röjningsbehov, även om det absoluta röjningsbehovet underskattas.

Kvalitativ validering i fält

De första intrycken i fält var över lag positiva, framför allt avseende variationen av predikterad tidsåtgång inom bestånden. Total tidsåtgång per objekt var svårare att utvärdera, men jämförelsevis mellan objekten verkade den totala tidsåtgången ha god överensstämmelse. Det vill säga ett objekt med låg predikterad tidsåtgång per hektar såg också i fält ut att kräva mindre tid för röjning och vice versa.

I fuktigare områden med rörligt markvatten så var det tydligt att det stora lövuppslaget också hade fått motsvarande utfall i skattningen. Se exempel i Figur 35 som motsvaras av det nordöstra området i Figur 34. Dessutom noterades att de områden med kortast predikterad tidsåtgång för röjning ofta låg högt i sluttningarna, där tall dominerade på fattigare marker.

Förutom de kvalitativa bedömningarna gjordes även mätningar av stamantal med röjsnöre på några provytor i röjningsobjekten. Mätningarna gjordes på två av objekten som besöktes i fält inom ett begränsat antal provytor, men visade ändå med tydlighet att fler stammar korrelerade med högre predikterad tidsåtgång.

Generellt sett var det också positiva reaktioner från deltagarna på den gemensamma fältdemonstrationen, och de flesta visade intresse av att testa modellens resultat vidare i egna tillämpningar. Många förslag framkom på användningsområden, exempelvis:

- Se variation inom beståndet (svårt att skatta)
- Identifiera områden med röjningsbehov
- Hitta och prioritera röjning (på landskapsnivå)
- Prioritering är mindre viktig för en privat markägare
- Budgetering och planering (ökad precision), internt och mot skogsägare/entreprenörer
- Ge underlag för prissättning även för röjare. En del röjare vill jobba på ackord.
- Ge möjlighet för digitala affärer
- Kostnad intressant, både nu och prognos framåt
- Sälla bort "icke röjning"
- Arbetsplanering för entreprenörer

Under övningen väcktes också nya frågor och förslag på vidare utvärdering och utveckling, till exempel:

- Filtrering av objekten där man på förhand har kännedom om att röjning inte behövs
- Filtrering med data från laserskanning
- Kalibrering av uppskattning per pixel behövs
- Hur ändrar sig utfallet över tid?
- Kan en visualisering på logaritmisk skala vara givande?
- Hur funkar modellen på gran och andra biotoper?

Diskussion

Osäkerheter och utmaningar i fältdatainsamlingen

Det fanns betydande utmaningar i fältdatainsamlingen:

Mobilerna som GNSS-appen var installerade på behövde hållas laddade och appen behövde startas manuellt inför varje skift. Osäkerheten i GNSS-positioneringen var oklar då appen inte angav någon felskattning.

För att genomföra insamling av data från röjsågar behövde de särskilda röjsågarna med Fleet-sensor användas och röjsågsdata behövde laddas upp till Husqvarnas molnlagringssystem. Røjarna var vana vid ett visst märke av sågar och kunde ibland uppleva det som en utmaning att byta till Husqvarna-sågar. Fleet-sensorn skulle dock gå att använda på röjsågar oavsett tillverkare, även om informationen som kan samlas blir mer begränsad.

En annan källa till osäkerhet var svårigheten att skilja mellan olika orsaker till att en pixel hade hög röjningstid. Berodde det på att pixeln faktiskt hade högt röjningsbehov eller var ovanligt svårrojd, eller på att røjaren stod still? Ursprungstanken med insamling av röjsågsdata var att kunna hantera den typ av osäkerhet genom att filtrera bort de punkter där Fleet-sensorn visat att röjsågen varit i Idle mode (på tomgång). Det blev tyvärr inte möjligt till följd av problemen med röjsågsdatainsamlingen. Det vore fördelaktigt om Fleet-sensorn även hade loggat koordinater, så att endast en datakälla behövdes, i stället

för både mobilapp och sensor, och att Fleet-sensorn registrerade (summerade) data i tätare intervall än 15 minuter.

Utmaningar med rasterdata från Sentinel-2

Upplösningen i satellitdata är 10 m, och i vissa fall baserat på data med upplösning 20 m omsamplat till 10 m av Skogsstyrelsen. 10 m får anses vara en grov upplösning för den aktuella tillämpningen då det inte är tillräckligt för att identifiera enskilda träd. Dock matchar sagda upplösning GNSS-koordinaternas positioneringsfel om cirka 5 meter, och frågan är om det hade varit meningsfullt att ha satellitdata med betydligt bättre upplösning än GNSS-positioneringen.

Styrkan med satellitbilder från Sentinel-2 är den kostnadsfria tillgången samt den uppbyggda infrastrukturen för datatillgänglighet. Utmaningen med att säkerställa tillräckliga många molnfria bilder för Sverige är dock inte försumbar; satelliten passerar över Sverige varannan eller var tredje dag, och erfarenheten visar att färre än hälften av dessa bilder är fria från moln eller artefakter. I framtiden kommer sannolikt en ny generation Sentinel-satelliter med högre upplösning skjutas upp, även om planerna vid rapportens skrivande endast är på diskussionsstadiet.

Trädhöjdsrastret har en upplösning på 2,0 meter i xy-planet och 0,1 meter i höjddled. Detta är heller inte tillräckligt för att hitta enskilda träd, även om Skogsstyrelsen anger att enskilda vuxna träd på hyggen syns väl.


En alternativ metodik (pipeline) för att hämta och bearbeta raster från Sentinel-2 via Google Earth Engine samt beräkna färgdiagrammet på beräkningsytor i stället för enskilda pixlar redovisas i Appendix A.

Alternativ till Sentinel-2 vore exempelvis högupplösta bilder från kommersiella satelliter, exempelvis Planet SKYSAT med upplösning på 0,1 meter, det vill säga 100 gånger bättre än Sentinel-2 (Planet 2023). Eftersom röjningsmodellen kommer behöva tränas om över tid innebär det dock en väsentlig kostnad för användarna. Planet-satelliterna har heller inte de infraröda SWIR-banden, till skillnad från Sentinel-2.

Den aktuella modellen använde satellitbilder från en tidpunkt innan röjning, nämligen juli 2020. En möjlig utveckling av modellen kunde vara att i stället använda en förändringsbild (skillnaden mellan två bilder tagna vid olika tidpunkter) eller en tidsserie av bilder, exempelvis:

- Från innan lövsprickning, exempelvis april i södra och mellersta Sverige och maj till första halvan av juni i norra Sverige
- Från efter lövsprickning men innan höstfärgändring, exempelvis från juli
- Eventuellt även en bild med höstfärger, exempelvis från september till första halvan av oktober

En tidsserie med sådana bilder demonstreras i Figur 39.



Figur 39. Exempel på tidsserie av satellitbilder innan och efter röjning (2018-2019 respektive 2021) samt innan och efter lövsprickning (april respektive juli) och vid begynnande höst (september).

Modellens användbarhet och möjlig implementering

De första reaktionerna på modellen har varit positiva men resultaten har ännu inte testats i större skala med större variation i till exempel skogstyper och geografi, det är därför värt att poängtera att det återstår en hel del arbete innan modellen är redo för operativ användning. Efter projektets slut fortlöper arbetet dels med vidareutveckling av modellen av Skogforsk, dels med att producera kartor med befintlig modell på ett storskaligt geografiskt område i en produktionsmiljö hos Field. Att dessa satsningar görs tillsammans med aktörer på marknaden visar att det finns en framtidstro på användning av metoderna som projektet har resulterat i.

Hur användbar modellen är i befintligt skick för olika tillämpningsområden är ännu inte utvärderat men sannolikt kommer anpassningar att behöva göras till varje region och företag som önskar nyttja den. Antingen genom att modellen utvecklas och anpassas till lokala förhållanden och olika tidpunkter på året för satellitbilder eller att modellens resultat filtreras och korrigeras för att anpassas till olika förutsättningar (kalibrering).

I projektet valdes tidigt att använda tidsåtgång för röjning som målfunktion för modellen, eftersom det både möjliggjorde genomförande av datainsamlingen och samtidigt kunde vara ett flexibelt mått som kunde anpassas till olika användningsområden senare. Det går att tänka sig många olika alternativ att kvantifiera behovet eller prioriteten av röjning som exempelvis kostnad för utfört arbete eller total tidsåtgång för röjning av objekten.


Samtidigt vore det också önskvärt att löpande kunna validera och återföra träningsdata till modellen som då kan förbättras.

Implementationen av modellen är gjord i två steg. Först behövde alla indatakällor skalas om och sättas ihop till ett gemensamt dataset över det område som skall analyseras. Systemet är byggt för att både analysera små områden/enstaka bestånd, samt för storskalighet med heltäckande material över exempelvis ett innehav. Flera av indatakällorna är relativt statiska och bygger på de nationella laserskanningarna, och behöver därför bara produceras och bearbetas en gång. Satellitbilderna är det som har en högre uppdateringsfrekvens, och därför är tanken att det datasetet ska gå att uppdatera kontinuerligt. För att få heltäckande material från satellitbilder behövs molnfria bilder sättas ihop till en mosaik. Tanken är att detta ska göras årsvis på bilder från sommarmånader, för att matcha träningsdata. All den här bearbetningen har gjorts till ett produktionssystem för att enkelt ta fram data på nya områden, samt uppdatera data i framtiden.

För mer operativ användning behöver den framtagna modellen byggas in i ett motsvarande produktionssystem (steg två). Detta har påbörjats, men tillämpningen av modellen befinner sig fortfarande i en utvecklingsmiljö.

Andra användningsområden för de insamlade fältdata

Förutom att utgöra fältreferens till skattning av röjningsbehov med AI finns det potential att använda data från utförda röjningar för planering av röjlagens arbete. Genom att enskilda röjares rörelser över ett objekt registreras går det att lära sig hur olika upplägg av arbetet påverkar effektivitet och kvalitet i arbetet (Figur 40), vilket skulle kunna stötta röjlagens egna metodutveckling. Eventuella studier på området måste dock göras med hänsyn till datas integritetskänsliga natur.



Figur 40. Exempel på GNSS-koordinater omvandlade till gångriktningsvektorer, från starten av röjningen (0 minuter) till slutet av röjningen (275 minuter).

Avslutande reflektioner

Prediktionsmodeller har potential att både underlätta planeringen för skogsföretagens planerare och planeringen för arbetslag. Med geodata som grund kan stödverktyg implementeras för att ge arbetslagen bättre vägledning och riktning, säkerställa att

teamen är väl förtrogna med terrängen och optimerar deras navigering. Dessutom möjliggör teknikintegration en sömlös samverkan med GIS, analys- och planeringsplattformar. Att dra nytta av GNSS-data förbättrar ytterligare arbetsmetoderna och bidrar till bättre maskinutnyttjande och generell operationell effektivitet. Olika terrängar och vegetationstyper leder till geografiska variationer i arbetssätt vid röjning, vilket kräver anpassning av modellen. Kvalitetskontroll är av stor vikt. Noggrannheten i tidsåtgången, som är en proxy för röjningsintensitet, behöver också förbättras ytterligare.

Informationsgap finns, särskilt frånvaron av relevanta detaljer om röjsågar utöver data om motoregenskaper. Idealt hade varit om Fleet-sensorn kunnat ge ett mått på antal röjda stammar, exempelvis genom tryckkänslighet. Då hade antalet borttagna stammar kunnat fungera som en proxy för att förbättra bedömningen av röjningseffektivitet. Utmaningar finns även hos satellitdata och bivariabler. Den spatiala upplösningen på satellitbilder och kartprodukter vid 10/20 m kan anses vara för grov för att tillämpas på AI-modeller av typen CNN. Variationer i satellitbildkvalitet över stora, spridda områden skapar också utmaningar, liksom begränsningarna i geografisk täckning hos trädhöjdsrelaterade geodataprodukter.

Forskningsetiken, EU-GDPR och ingångna avtal ställer krav på hänsyn när det gäller kopplingen mellan GNSS-data och individer. Projektets avsedda lösning prioriterar anonymisering och hanterar etiska överväganden inom den bredare diskursen som formar skogsbrukets tillvägagångssätt vid hanteringen av maskindata. I denna dialog deltar Skogforsk aktivt och säkerställer att etiska överväganden kring maskindata av denna natur integreras i pågående samtal om skogsbrukets utveckling.

Vidare arbete

Både datainsamlingen och modellen har flera tänkbara vidareutvecklingsområden:

- Undersöka ytterligare möjligheter att samla in träningsdata, både samma och nya typer
- Undersöka om samma modell kan användas även för norra Sverige eller om separata modeller behövs för olika regioner
- Testa befintlig modell på ytterligare områden
- Träna om modellen på data från fler typer av skogar samt redan röjda bestånd med hjälp av ny datainsamling
- Träna på satellitbilder från flera säsonger
- Träna på satellitbilder från efter röjningstillfället
- Undersöka vilka band/variabler som är mest relevanta för modellen
- Undersöka vilka "hidden layers" (kombinationer av variabler) som är mest relevanta för modellen
- Presentation och tolkning av slutprodukten, till exempel relativt röjningsbehov eller klassbaserat
- Andra tillämpning av datasetet, till exempel för arbetslaget att planera gångmönster eller för att prediktera underväxtröjning

Intresset för röjningsprediktion är stort inom skogsbruket och arbetet kommer att tas vidare, bland annat inom ramen för forskningsprogrammet Mistra Digital Forest.

Slutsatser

Den data-drivna utvecklingen har potential att revolutionera olika aspekter av skogsbruket, inte minst ungskogsröjning. Det inkluderar en ambition att främja mer objektiva kontraktsförhandlingar med små skogsägare och entreprenörer, med målet att uppnå transparenta och rättvisa avtal som gynnar alla parter. Samtidigt får intressenter ytterligare stöd för operativ planering, utrustade med förbättrade verktyg för att underlätta ett informerat och effektivt beslutsfattande under planeringsfasen, vilket bidrar till smidigare skogsbruksåtgärder.

Från projektet RøjSAT dras följande slutsatser:

- Det gick att träna en AI-modell baserat på öppna satellitdata och skogsdata som kan förutsäga röjningstiden i ungskogsobjekt i södra Sverige
- Data från mellersta Sverige kan troligen inkluderas i samma modell, detta är ett lämpligt vidareutvecklingssteg
- Troligtvis behövs en separat modell för norra Sverige, givet långsammare tillväxt, större röjningsobjekt och annorlunda arbetsmönster
- Modellens användbarhet på fler delar av landet behöver utvärderas
- Röjsågsdata samlades in men kunde inte användas på grund av ofullständig datainsamling och alltför låg upplösning på data
- Många testade modeller tenderade att underskatta röjningstiden i ett 10×10 meters område, och hade särskilt svårt att prediktera långa röjningstider
- Det är sannolikt att modellen behöver kontinuerlig träning för att fungera som bäst

I ett eventuellt fortsättningsprojekt bör ytterligare omsorg läggas på datainsamlingen.

Referenser

- Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., Devin, M., Ghemawat, S., Irving, G., Isard, M. & others. 2016. TensorFlow: A System for Large-Scale Machine Learning. Proceedings of the 12th USENIX Symposium on Operating Systems Design and Implementation (OSDI '16), pp. 265-283, November 2–4, 2016, Savannah, GA, USA.
- Abiodun, O., Jantan, A., Omolara, A., Dada, K., Mohamed, N. & Arshad, H. 2018. State-of-the-art in artificial neural network applications: A survey. *Heliyon*, 4, 1-41.
- Dahl, M. 2001. Satellitbildsbaserade skattningar av skogsområden med röjningsbehov. Master thesis, SLU Sveriges Lantbruksuniversitet, 1-35 s.
- Fransson, T. 2014. Användning av drönare vid skogsvårdsplanering. BSc thesis, Linnéuniversitetet, 1-49 s.
- Husqvarna. 2023. HUSQVARNA Fleet Services™ maskinsensor. Husqvarna. URL: <https://www.husqvarna.com/se/fleet-services-utrustning/fleet-services-maskinsensor/> [Hämtad 2023-03-21].
- Hyvönen, P. 2002. Kuvioittaisten puustotunnusten ja toimenpide-ehdotusten estimointi k-lähimmän naapurin menetelmällä Landsat TM-satelliittikuvan, vanhan inventointitiedon ja kuviotason tukiaineiston avulla. *Metsätieteen aikakauskirja*, 3, 363-379.
- Kuhn, M. 2008. Building Predictive Models in R Using the caret Package. *Journal of Statistical Software*, 28, 1 - 26.
- Naturvårdsverket 2020. Nationella marktäckedata 2018, basskikt - Produktbeskrivning. Naturvårdsverket. 58 s.
- Olsson, H. 1994. Changes in satellite-measured reflectances caused by thinning cuttings in Boreal forest. *Remote Sensing of Environment*, 50, 221-230.
- Persson, A. 2019. Satellitdatahantering hos Skogsstyrelsen (PPT). Skogsstyrelsen. 1-32 s.
- Persson, A. & Bank, H. 1998. Användning av satellitdata - hitta avverkad skog och uppskatta lövröjningsbehov. Skogsstyrelsen. 1-42 s.
- Pettersson, M. 2005. Användning av satellitdata för lokalisering av skogsområden där lövröjning bedöms angelägen. Master thesis, SLU Sveriges Lantbruksuniversitet, 1-33 s.
- Pettersson, N., Fahlvik, N. & Karlsson, A. 2012. Röjning, Skogsstyrelsen, 75 s.
- Planet 2023. Planet Imagery Product Specifications. 92 s.
- Ripley, B. D. 1996. Pattern Recognition and Neural Networks, Cambridge, Cambridge University Press, 415 s.
- Schmitt, M., Hughes, L., Qiu, C. & Zhu, X. 2019. Aggregating cloud-free Sentinel-2 images with Google Earth Engine. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, IV-2/W7, 145-152.
- Skogsstyrelsen 2020a. Lutning från Lantmäteriets nationella laserdata– teknisk specifikation. 3 s.

- Skogsstyrelsen 2020b. Markfuktighetskarta samt datum för laserskanning– teknisk specifikation. 3 s.
- Skogsstyrelsen 2020c. Sentinel2 – teknisk beskrivning. Dokumentversion 1.0. Skogsstyrelsen. Published 2020-02-27. 1-7 s.
- Skogsstyrelsen 2020d. Trädhöjdsraster från Lantmäteriets laserskanning samt flygbilder– teknisk specifikation. 5 s.
- Skogsstyrelsen 2022. Utförda avverkningar – produktbeskrivning. Skogsstyrelsen. 1-3 s.
- Tolstikhin, I., Houlsby, N., Kolesnikov, A., Beyer, L., Zhai, X., Unterthiner, T., Yung, J., Steiner, A., Keysers, D., Uszkoreit, J., Lucic, M. & Dosovitskiy, A. MLP-Mixer: An all-MLP Architecture for Vision. 35th Conference on Neural Information Processing Systems (NeurIPS 2021), 2021 Online Conference, Canada. 1-12.
- Trybom, K. 2000. Röjningsbehov med hjälp av satellitbilder. Bachelor, Karlstads universitet, 62 s.
- Watt, M. S., Meredith, A., Watt, P. & Gunn, A. 2013. Use of LiDAR to estimate stand characteristics for thinning operations in young Douglas-fir plantations. New Zealand Journal of Forestry, 43, 1-10.
- Wright, M. N. & Ziegler, A. 2017. ranger: A Fast Implementation of Random Forests for High Dimensional Data in C++ and R. Journal of Statistical Software, 77, 1 - 17.
- Zhang, A., Lipton, Z. C., Li, M. & Smola, A. J. 2023. Dive into Deep Learning, chapter 5.1 - Multilayer Perceptrons. Cambridge University Press.
- Zou, J., Han, Y. & So, S.-S. 2009. Overview of Artificial Neural Networks. In: Livingstone, D. J. (ed.) Artificial Neural Networks: Methods and Applications. Totowa, NJ: Humana Press.
- Ågren, A., Larson, J., Paul, S., Laudon, H. & Lidberg, W. 2021. Use of multiple LIDAR-derived digital terrain indices and machine learning for high-resolution national-scale soil moisture mapping of the Swedish forest landscape. Geoderma, 404, 115280.

Appendix A – Alternativ metodik

A.1 Datainhämtning- och bearbetning

A.1.1 Generell datainhämtning

Samma metod för behandling av GNSS-koordinater och bivariabler ('auxiliaries') som i övriga rapporten användes, bortsett från att SLUs produkt Markfuktighet användes istället för Skogsstyrelsens produkt Markfuktighetskartan.

Röjsågsdata användes ej. Däremot användes objekt från både Södra och Mellanskog i framtagningen av maskininlärningsmodellen.


A.1.2 Sentinel-2

För att bearbeta och analysera flera scener av satellitbilder på ett stort antal spridda områden, till exempel skogsobjekt som är planerade för avverkning, kan Google Earth Engine (GEE) via Google Cloud Platforms (GCP) molnbaserade datamiljö vara extremt effektiv, inte minst för att producera molnfria bilder (Schmitt m.fl. 2019).


Den bildmosaik som används för analys, kallad "molnfri," genererades med hjälp av algoritmen som beskrivs av Schmitt m.fl. (2019) och är tillgänglig på Google Earth Engine-plattformen. Denna algoritm beräknar olika kvalitetsmått både på pixel- och bildnivå genom att analysera en samling Sentinel-2-bilder som tagits vid olika tidpunkter. Dessa mått används sedan för att skapa en sammansatt bild utan moln. Pixelnivåmättet kallat 'Quality Score' representerar en förbättrad molnsannolikhetsmask för alla pixlar över hela bildsamlingen och särskiljer olika typer av moln (till exempel lätta cirrusmoln jämfört med mer ogenomskinliga moln). Algoritmen försöker också eliminera molnskuggområden genom bildmorfologi. Dessutom tilldelas varje bild ett 'Quality Pixel Percentage'-mått baserat på pixelvisa värden från 'Quality Score'. Denna procentandel återspeglar andelen högkvalitativa pixlar som används för att skapa den molnfria bildmosaikens och bestäms av en uppsättning fördefinierade regler. Noterbart är att den ursprungliga algoritmen modifierades något för att beräkna 'Quality Pixel Percentage'-scoren enbart för de angivna skogsobjekten istället för hela bilden. För träning av modellen skapades "molnfria" månatliga mosaiker för 2019 och 2020 med fyra tidsintervall i åtanke: maj/juni, juni/juli, juli/augusti och september/oktober, och sedan medelvärdesbildades över motsvarande perioder under olika år. Mosaikerna skapades med en upplösning på 10 meter genom att endast använda de Sentinel-2-band som naturligt produceras med en spatial upplösning på 10 och 20 meter.

Den främsta fördelen med att använda molnbaserade plattformar för satellitbilda-behandling ligger i den beräkningsmässiga effektiviteten och fria tillgången till toppmoderna algoritmer. Å andra sidan följer det med vissa begränsningar när man arbetar i GCP med en utvecklarprofil inom det kostnadsfria nivåkontot, särskilt gällande mängden data som kan bearbetas och exporteras. I vissa situationer, som vid analyser av Sentinel-2-bilder som täcker stora områden (flera tiles), kan molnbearbetning och/eller export av data till lokal lagring (exempelvis Google Drive) avbrytas på grund av begränsningar som GCP inför. Dessutom kräver den kommersiella användningen av Google Cloud Engine licensiering, vilket innebär ytterligare kostnader. Trots det möjliggör den kommersiella användningen av GCP att skala upp och effektivisera bearbetningen och modellimplementeringen, och kommer att eliminera begränsningarna hos användningen på den kostnadsfria nivån.

Att ha ett dedikerad REST-API för att få tillgång till och ladda ner Sentinel-2-bilder från olika källor, såsom Skogsstyrelsen, erbjuder ett kostnadsfritt alternativ till GCP när det gäller dataanskaffning. Trots det måste analysen (dvs. bildbehandling, mosaikläggning, med mera) genomföras på backend-sidan.




Figur A. 1. Sentinel-2 'molnfria' månatliga mosaiker för 2019.



Figur A. 2. Sentinel-2 'molnfria' månatliga mosaiker för 2020.


Ett exempel på överensstämmelsen mellan ett färgdiagram (sekunder per pixel) och de satellitband och bivariabler ('auxilliaris') som maskininlärningsmodellen tränas på visas i Figur A. 6:



Figur A. 3. Överensstämmelse mellan ett urval av de rasterband som maskininlärningsmodellen tränas på och färgdiagram över tidsåtgång. Översta två raderna: band från Sentinel-2. Nedersta raden: objekt, koordinater, färgdiagram, markfuktighetskarta. Alla bilder visar samma objekt.

A.1.3 Aggregering och modellering

De resulterande värmekartorna delades upp i små områden kallade beräkningsytor (Figur A. 4) med hjälp av grafbaserade klustermetoder baserade på kallade 'community detection'-algoritmer. Det antogs att användning av en mikroplatsrepresentation av data skulle jämna ut de spatiala osäkerheterna i GNSS-informationen. Slutligen aggregerades också övriga rasterbaserade produkter på beräkningsytenivå för att bevara den 1:1-korrespondens mellan fältdata (det vill säga färgdiagram) och träningsdata.



Figur A. 4. Färgdiagram över tidsåtgång (höger) framtagen genom aggregering av GNSS-koordinaterna (vänster) över beräkningsytor. Notera att det 'tomma' området utan GNSS-koordinater i den vänstra bilden har bedömts sakna röjningsbehov.


Prediktionen implementerades som en ensemble av två maskininlärningsmodeller, nämligen modellgenomsnitt för Feed-Forward Neural Networks (FFNN, avNNet) och Random Forests. avNNet-modellen byggdes och tränades med hjälp av 'caret' (Ripley 1996; Kuhn 2008) i den statistiska programvaran R. Det snabba R-paketet 'ranger' (Wright & Ziegler 2017) användes för att implementera Random Forest-modellen.

Anledningen till att använda denna specifika kombination av modeller är tvåfaldigt: (1) att använda en flexibel modell (det vill säga ett neuralt nätverk) som kan fånga upp icke-linjära samband och extrapolera, och (2) att minska möjliga extrapolationsfel genom att introducera Random Forest-modellen som endast kan interpolera med hjälp av observationer i träningsdatamängden, och därmed balansera möjliga extrapolationsfel som induceras av neuralt nätverk. Dessa resultat bör hanteras med försiktighet eftersom den prediktiva prestandan hos ensemblen under implementeringen kan vara överlägsen när träningen utförs på hela datasetet. Den valda modellkombinationen använder tabulärt (kolumnbaserat) input och etablerar en strukturerad ram för dataintegration och analys.


A.2 Resultat och diskussion

Utvärdering av skogsbruksåtgärder är en komplex utmaning som kräver avancerade metoder. Färgdiagram över tidsåtgång, mätta i sekunder per pixel, fungerar som ett dynamiskt svar och ger insikter om röjningsverksamhetens effektivitet. Genom att använda semantisk segmentering och bildregressionstekniker delas områden metodiskt upp i segment, vilket skapar en komplex beräkningsutmaning. Utmaningar uppstår


särskilt vid träning med områden som har oregelbundna former och en begränsad storlek på datasetet (antal objekt). Olika valideringsmått för olika objekt visas i Figur A. 5 till Figur A. 6.




Figur A. 5. Exempelobjekt #1. Grav underestimering av total röjningstidsåtgång i beräkningsytor ('micro-sites') och samtidigt acceptabel precision.



Figur A. 6. Exempelobjekt #2. Måttlig underestimering av total röjningstidsåtgång i beräkningsytor ('micro-sites') och samtidigt acceptabel precision.



Figur A. 7. Exempelobjekt #3. Grav överestimering av total röjningstidsåtgång i beräkningsytor ('micro-sites') och samtidigt låg precision.



Figur A. 8. Exempelobjekt #4. Hög systematisk avvikelse av total röjningstidsåtgång i beräkningsytor ('micro-sites') och samtidigt låg precision.

Korsvalidering på områdesnivå gav ett ungefärligt medianabsolutfel på cirka 38% för Mellanskogs och Södras objekt. Det är värt att notera att det finns en konsekvent tendens att underskatta tidsåtgången. Sveaskogs objekt inkluderades i slutändan inte då de gav upphov till betydande fel i modellen, sannolikt på grund av att GNSS-koordinater saknades över stora delar av röjningsobjekten (Figur A. 7 och Figur A. 8). Orsaken till

detta är oklar, men kan antingen bero på att objektpolygonen inkluderade delområden som saknade röjningsbehov, eller problem i loggningen eller insamlingen av GNSS-data.

Trots att ingångsdata för modelleringen var på pixelnivå med måttet 10×10 m, aggregerades prediktionen till beräkningsytanivå. Motiveringen var att jämna ut eventuella positioneringsfel och annan typ av brus relaterat till insamling av fältdata. Dessutom öppnar användningen av en relativt liten träningsdatamängd för stora extrapolationsfel. Att aggregera prediktionen hjälper till att minska variansen samtidigt som det ger ett resultat (prediktiva färgdiagram) som är lätt att tolka och använda inom praktiskt skogsbruk.

Appendix B - Fältinstruktion RøjSat v. 1.1

Inledning

Foran Sverige, Skogforsk och Örebro universitet har tilldelats medel av Vinnova för att utveckla AI-metoder för att se på röjningsbehov utifrån satellitdata. Intressentföretag i projektet är Sveaskog, Södra skogsägarna och Mellanskog. I projektet görs kopplingar mellan tidsstudier av röjare/ insamlade beståndsdata och spektralinformationen i satellitscener, där olika AI-metoder testas för att nå bästa förklaringsgrad. Projektet ska leda fram till en fungerande metodik för de flesta biotyper över hela landet och ett fungerande produktionssystem för marknaden.

Denna fältinstruktion beskriver hur fältdatainsamling i projektet ska ske. I stora drag består datainsamlingen av två delar: tracklogg av GNSS-positioner och beståndsvisa skogliga uppgifter, vilka beskrivs separat nedan.

Tracklogg av GNSS-position

GNSS-loggar är en mycket central del av projektet, vilka kommer att nyttjas för att koppla ihop spektralanalysen i satellitbilderna med faktisk tidsåtgång, för att kunna säga något om röjningsbehovet på en enskild okänd röjningstrakt.

GNSS-loggarna samlas in med appen "GPS Logger". Denna app finns enbart till Android-telefoner och hämtas kostnadsfritt från Google Play. Instruktion nedan beskriver hur programmet sätts upp och används. All data är anonymiserad och skickas automatisk till Forans server i Linköping för bearbetning. Ingen insamlad GNSS-information kommer röjningsentreprenörernas uppdragsgivare tillgodo i något led. Loggning ska startas när man går in i beståndet, och stoppas när man inte längre röjer. För att inte samla in felaktiga data bör man hålla sig utanför beståndet när man inte röjer, exempelvis vid arbetspauser.

GPS Logger


För att appen ska fungera på ett ändamålsenligt sätt, krävs att instruktionerna i listorna nedan följs.

Nedladdning av "GPS Logger" (endast tillgänglig för Android)

Första steget är att hämta appen "GPS Logger for Android" från Google Play. Det finns några olika varianter för att spåra GNSS-position, så det är viktigt att appen som är skapad av utvecklaren som heter Mendhak väljs.

Automatisk inställning av användarprofil i appen "GPS Logger"

1. Starta "GPS Logger"-appen och tryck på meny-knappen längst upp till vänster (tre streck).
2. Tryck på "Default Profile" och välj sedan "From URL".



3. Skriv sedan den adress du har fått separat skickat till dig. Nu laddas alla inställningar som behövs in automatiskt.

Inställningarna gör att "GPS Logger"-appen kan starta automatiskt och logga punkter med ett jämnt intervall, samt även skicka dem automatiskt till Forans server i Linköping. Vill man starta eller stoppa loggning kan man göra det manuellt med en knapp som syns i huvudvyn i appen.

Inställning av telefonens batterioptimering för appen "GPS Logger"

För att loggning ska kunna ske även när appen inte är aktiv och telefonens skärm påslagen, behöver man göra en särskild inställning för batterioptimering. Menyerna för inställning av batterioptimering ser lite olika ut på olika modeller av telefon som används. Något av följande alternativ bör kunna vara vägledande för att göra de inställningar som behövs.

Alternativ 1:

1. Gå till telefonens inställningar
2. Gå till inställningar för Appar, välj "GPS Logger" i listan
3. Välj inställningar för Batteri
4. Tryck på Batterioptimering, välj "GPS Logger" i listan
5. Välj alternativet "Optimera inte"

Alternativ 2:

1. Gå till telefonens inställningar
2. Gå till inställningar för Appar, välj "GPS Logger" i listan
3. Välj inställningar för Batteri/Batterianvändning
4. Tryck på Batterioptimering, välj "Optimera inte"

Bestandsvisa skogliga uppgifter

Ett antal parametrar samlas in i ForanAtlas, vilket är ett webbaserat kartstöd för fältarbete. Denna fungerar både på Android och iOS. Insamlingen sker enkelt genom att logga in, skapa en punkt och fylla i det indataformulär som kommer upp. Även detta dataset lagras automatiskt på Forans server i Linköping. Det går bra att samla in data även utan fungerade uppkoppling i fält och då data kommer att synkroniseras med databasen då man får uppkoppling igen.

Denna data samlas in av endast en person i arbetslaget. Är röjningstrakten delad i helt separerade delytor, så skapas en punkt per delyta. **Samtliga data ska gälla utseendet på beståndet innan påbörjad röjning** och all data ska uppskattas på beståndsnivå, dvs inga provytemätningar behöver göras. Tänk på att **skapa punkten med skoglig information innanför yttergränsen för aktuellt bestånd**. Detta för det ska bli enklare att koppla punkten mot beståndet i senare skede.

Om någon parameter förändras under arbetets gång (t ex antal röjare), så öppna upp punkten igen i Atlas och gör en korrigering.

Följande parametrar samlas in:

Trädslagsblandning - som fördelning av Tall, Gran och Löv i 10-tals procent.

Ståndsortindex (SI) - Anges som T eller G, i tvåmetersklasser. Lövbönitet anges som G.

Medelhöjd barr - i decimeter

Medelhöjd löv - i decimeter

Medelålder - Anges i år beräknat som antal grenvarv +2. Räkna på representativ tall om sådan finns.

Medeldiameter - Anges i cm.

Stamantal - Anges i klasserna 1-3. 1- Mindre än 1500 st/ha, 2- 1500-3000 st/ha, 3- mer än 3000 st/ha

Är beståndet röjt tidigare - Om det är röjt tidigare, ange JA. Annars NEJ.

Blockighet - Anges i klasserna 1-3. 1- Jämn mark/ Färre antal mindre block, 2- Måttligt/Rikligt med mindre block och/eller enstaka större block, 3- Storblockigt.


Antal röjare- Ange antalet olika röjare som arbetat på trakten. Detta för att veta att alla data ifrån telefonerna har kommit in.

Fritext - Om information finns för att förklara övriga data. Använd gärna detta fält ofta, då det ger stor förståelse. De kan gälla t ex om någon telefon strular eller inte varit påslagen, om större ytor finns i beståndet som av någon orsak inte ska röjas.

Foto - För att ge en bild och en förståelse av det aktuella objektet. Tas direkt genom indataformuläret.

ForanAtlas

1. Öppna en webbläsare (Chrome eller Safari). Skriv in **atlas.foran.se**. Då hamnar du på **account.foran.se**, vilken sköter alla inlogg och rättigheter. Logga in med användarnamn och lösenord som ni har tilldelats.



Foran Login

Användarnamn / mailadress

Användarnamn / mailadress


Lösenord

Lösenord


Logga in

[Glömt lösenord](#)


2. Då kommer du med automatik in i Atlas. Välj då ditt workspace, **RöjSat**, genom att trycka på den raden.




3. En bakgrundskarta laddas in om du är online, annars är bakgrunden vit. Atlas jobbar med dolda "revolvermenyer", vilka bara dyker upp när man trycker i kartan. Dessa ser olika ut beroende på var du trycker. Börja med att trycka i kartan (eller på den vita bakgrunden) och få upp nedan meny. Tryck på symbolen längst upp. Då får du frågan om du vill låta Atlas se din position, tryck **Ja**.



4. Tryck i kartan och på samma symbol igen. Då kommer kartan zooma till den plats du befinner dig och illustrera denna med en grön punkt.



5. När du ska samla in data i fält: stå inom avgränsningen för röjningsbeståndet, tryck på din position (den gröna punkten) och sedan på +-tecknet i menyn. Då skapas en röd punkt, se nedan. Tryck på punkten en gång till och bekräfta dess placering med "boken".



6. När du gjort detta så kommer nedan indataformulär upp. Fyll i alla datafält och tryck på Submit. Då har inlagd information på beståndet sparats. De flesta fält har dropdown-menyer, men det går att skriva in direkt också. Alla fält utom fritextfältet är obligatoriska och trädslagsblandningen måste summera till 100 procent. Annars går formuläret inte att spara.

13:28 atlas.foran.se/workspaces/5e


Beståndsinfo

Trädslagsblandning


Andel tall	Medelhöjd barr (decimeter)
Andel gran	Medelhöjd löv (decimeter)
Andel löv	Medelålder (antal grenvarv +2)
	Medeldiameter (centimeter)
	Stamantal
	Tidigare röjt
Ståndortsindex (SI)	Blockighet
Medelhöjd barr (decimeter)	Antal röjare
Medelhöjd löv (decimeter)	Fritext
Medelålder (antal grenvarv +2)	Foto CHOOSE IMAGE

CANCEL SUBMIT

7. Ett förtydligande gällande att ta ett foto. Ett foto ska samlas in på någon del av röjningen, för att få ett synintryck av beståndet. Ta alltid horisontella (liggande) foton. Gör så här: 1. Tryck på **Choose Image**, 2. tryck på bilden med pilen i mitten, 3. Ta bild (godkänn användning av fotoappen om så frågas), 4. Tryck **Submit**.



Övriga menyval i Atlas



Visar din position i Atlas/aktiverar GNSS.



Stänger av din GNSS-position.



Skapar en punkt/aktiverar indataformulär för valt lager. (Finns bara ett lager i RöjSat.)



Skickar vald position i kartan för navigering i Google Maps.



Tänder och släcker lager, ändrar lagerföljd, sätter genomskinlighet och sköter manuell export av datalager. Kommer inte att behöva nyttjas i RöjSat.




Verktyg för att mäta avstånd och areal.



Ändrar aktivt vektor-lager. Kommer inte att behöva nyttjas i RöjSat.

Appendix C



Figur A. 9. Kartvy från Husqvarna Fleet Services dashboard, med såg- och platsnamn anonymiserat.