



Automatisk detektering av döda träd från flygbilder

Jämförande studie av djupinlärningsmodell mellan två försöksytor

Saga Stålhandske

Vera Persson

Självständigt arbete • 15 hp

Sveriges lantbruksuniversitet, SLU

Fakulteten för skogsvetenskap/ Institutionen för Skogens ekologi och skötsel

Skogsvetarprogrammet

Kandidatarbeten i Skogsvetenskap • 2025:11

Umeå 2025



Automatisk detektering av döda träd från flygbilder. Jämförande studie av djupinlärningsmodell mellan två försöksytor

Automatic detection of dead trees from aerial images. Comparative study of deep learning model between two study sites

Saga Stålhandske, Vera Persson

Handledare: Jonas Bohlin, SLU, Institutionen för skoglig resurshushållning
Examinator: Therese Löfroth, SLU, Institutionen för vilt, fisk och miljö

Omfattning: 15 hp
Nivå och fördjupning: Grundnivå, G2E
Kurstitel: Självständigt arbete i Skogsbruksvetenskap
Kurskod: EX1015
Program/utbildning: Skogsvetarprogrammet
Kursansvarig inst.: Institutionen för skogens ekologi och skötsel
Utgivningsort: Umeå
Utgivningsår: 2025
Upphovsrätt: Bilderna i arbetet är författarnas egna om inget annat anges.
Serietitel: Kandidatarbeten i Skogsvetenskap
Delnummer i serien: 2025:11

Nyckelord: Vegetationsindex, NDVI, GNDVI, döda träd, fjärranalys, flygbilder, djupinläring, Faster RCNN

Sveriges lantbruksuniversitet
Fakulteten för skogsvetenskap
Institutionen för skogens ekologi och skötsel

Sammanfattning

Inom skogsskötseln är det av intresse av flera anledningar att veta hur många döda träd det finns och var de står. Syftet med denna studie har varit att träna en djupinlärningsmodell (Faster R-CNN) att detektera döda träd utifrån flygbilder och utvärdera dess träffsäkerhet. Modellen tränades på manuellt markerade datapunkter, så kallat väglett lärande, på en högupplöst ortofotomosaik i två vegetationsindex, NDVI (*Normalized Difference Vegetation Index*) och GNDVI (*Green Normalized Difference Vegetation Index*). Träningsdatat är från fastigheten Remningstorp i Västra Götaland, där modellen också validerats. Sedan applicerades samma modell på en liknande ortofotomosaik över Asa försökspark i Småland. Resultatet från Remningstorp var 0,79 F1-poäng men från Asa var F1-poängen 0,12. Resultaten visar på att man med djupinlärningsmodeller kan uppnå goda resultat av automatiserade analyser för att identifiera döda stående stammar, dock att modeller som tränats på data från ett område är svåra att använda på andra områden. Modeller som bygger på väglett lärande är beroende av manuellt kategoriserat träningsdata, vilket gör de tidskrävande att träna. Slutsatsen är att modeller för detektering av döda träd ännu inte är tillräckligt utvecklade för att vara praktiskt användbara på annat än mindre områden.

Nyckelord: Fjärranalys, vegetationsindex, NDVI, GNDVI, döda träd, flygbilder, djupinlärning, Faster RCNN

Abstract

In forest management, it is of interest for several reasons to know how many dead trees there are and where they are located. The aim of this study was to train a deep learning model (Faster R-CNN) to detect dead trees from aerial images and evaluate its precision. The model was trained on manually marked data points, so-called supervised learning, on an 8 cm resolution orthophoto of two vegetation indices, NDVI (*Normalized Difference Vegetation Index*) and GNDVI (*Green Normalized Difference Vegetation Index*). The training data is from the Remningstorp property in Västra Götaland, where the model was also validated. The same model was then applied to a similar orthophoto of Asa experimental park in Småland. The results from Remningstorp gives a F1-score of 0,79 but from Asa the F1-score was 0,12. This shows that deep learning models can achieve good results from automated analyses to identify dead trees and snags, but that models trained on data from one area are difficult to apply to other areas. Models based on supervised learning rely on manually categorised training data, making them time-consuming to train. The conclusion is that dead tree detection models are not yet sufficiently developed to be practically useful in more than small areas.

Keywords: Remote sensing, vegetation index, NDVI, GNDVI, dead trees, aerial photography, deep learning, Faster RCNN

Innehållsförteckning

Tabellförteckning	5
Figurförteckning	6
Förkortningar	7
1. Introduktion	8
2. Data och Metod	12
2.1 Data och dess insamling	12
2.1.1 Försöksområdena	12
2.1.2 Flygbilder	12
2.2 Tillvägagångssätt	13
2.2.1 Tränings- och testdata	13
2.2.2 Vegetationsindex	15
2.2.3 Skapa modell	16
2.2.4 Validering	17
3. Resultat	20
4. Diskussion	21
5. Slutsatser	23
Referenser	24
Bilaga 1. Exempelbilder från Remningstorp och Asa	28

Tabellförteckning

Tabell 1. Exempel på identifierade objekt vid detektion av döda träd på Remningstorp och Asa. Provytor gul färg och objekt identifierade av djupinlärningsmodellen är i rosa färg.....	18
Tabell 2. Redovisat resultat för provytor i valideringen för fastigheterna Remningstorp och Asa. Resultats som redovisas; är antal relevanta provytor alltså provytor som innehåll objekt av intresse. True positiv, False Negativ och False Positiv.	20
Tabell 3. Resultat av validering för fastigheterna Remningstorp och Asa. Tabellen redovisar resultat i precision, träfffrekvens och F1-poäng.....	20
Tabell 4. Exempelbilder från Remningstorp och Asa. Gul färg indikerar provytor och rosa färg identifierade objekt.	28

Figurförteckning

Figur 1. Försökspark Remningstorp (blå punkt) och försökspark Asa (röd punkt).	12
Figur 2. Urklipp ur ortofotomosaik i RGB över Remningstorp visandes levande träd (gröna) och döda träd (vita).	14
Figur 3. Urklipp ur ortofotomosaik i CIR över Remningstorp visandes levande träd (röda) och döda träd (vita).	14
Figur 4. Urklipp ur ortofotomosaik i NDVI över Remningstorp. Se klustret av döda träd (ljuslila) i nedre kanten i den röda ringen.	15
Figur 5. Urklipp ur ortofotomosaik i GNDVI över Remningstorp. Se klustret av döda träd (ljusröda) i nedre kanten i den blåa ringen.	16

Förkortningar

Förkortning	Betydelse
CIR	Colour-Infrared
CNN	Convolutional Neural Network
EN	Starkt hotad
GNDVI	Green Normalized Difference Vegetation Index
NDVI	Normalized Difference Vegetation Index
NIR	Närinfrarött
NT	Nära hotad
RF	Random Forest
RGB	Rött-Grönt-Blått
RGI	Simple Ratio Red/Green Index
SLU	Sveriges lantbruksuniversitet

1. Introduktion

Död ved är en viktig komponent i det boreala ekosystemet och att känna till den spatiala spridningen är av intresse av många anledningar. För det första har substratet död ved stor ekologisk betydelse för många arter av lavar, mossor, svampar, insekter och fåglar. På grund av förändrad skogsskötsel, timmerproduktion, och bekämpning av skogsbränder de senaste 200 åren, är mängden död ved i svenska skogar mindre än innan det industriella skogsbrukets början (Jonsson et al. 2016; Löfroth et al. 2023). En följd av detta är att många arter beroende av död ved idag är ovanliga och hotade. Av 17 505 skogslevande arter i Sverige är 1 023 beroende av död ved, och av dessa är 433 rödlistade vilket motsvarar 14% av de skogslevande arterna på rödlistan (SLU Artdatabanken 2025a). Stående döda stammar används bland annat av fåglar för att hitta föda, och som boplats av fåglar och fladdermöss. Exempelvis förekommer tretåig hackspett (*Picoides tridactylus*) i de flesta skogstyper som innehåller avsevärda mängder död ved (SLU Artdatabanken 2025b). Vissa arter är specifikt kopplade till färsk död ved, varav några exempel är granbock (*Monochamus sartor*) som är starkt hotad (EN), och aspborre (*Trypophloeus binodulus*) som är nära hotad (NT) enligt rödlistan (SLU Artdatabanken 2025c; SLU Artdatabanken 2025d). Eftersom många artförekomster är bundna till närvaron av död ved används ofta mängden död ved, i stället för en strikt artinventering, som ett kriterium vid naturvärdesbedömningar för att avgöra ett områdes potential för biologiska värden (SLU Riksskogstaxering 2024; Södra u.å.). En målbild som poängteras i certifieringsstandard är att öka mängden död ved i skogslandskapet, bland annat genom att vid slutavverkning och andragallring aktivt skapa död ved genom att göra högstubbar eller ringbarka träd (FSC 2020). För att på bästa sätt kunna prioritera områden med höga naturvärden i landskapsplaneringen är det av intresse att kunna identifiera var de största koncentrationerna av stående död ved finns.

För det andra kan vetenskapen om utbredningen av döda träd användas för inventering av skador som orsakats av granbarkborre (*Ips typographus*). Granbarkborrar är en av de vanligaste skogsskadegörarna i Sverige (Skogsstyrelsen 2021). De angriper stressade granar och dödar i avsevärd omfattning individer och hela trädgrupper. För att förhindra spridning av granbarkborrar bör färskt virke inte lämnas i skogen i sådana mängder att de skulle kunna utgöra spridningshärd för granbarkborrar och andra insekter som orsakar storskaliga skogsskador (SKSFS 2025:2). För att på ett effektivt sätt planera och genomföra sådana åtgärder så krävs överblick över skogens tillstånd. Hos Skogsdatalabbet som drivs av Skogsstyrelsen och SLU finns en funktion för att följa vitalitetsförändringar i barr- och blandskog, kallad "Förändringsanalys för att följa angreppen av granbarkborre" (Skogsstyrelsen & SLU 2025). Den baseras

på satellitbilder från Sentinel-2 vilket ger uppdaterade bilder med bara dagars mellanrum givet klart väder. Upplösningen på satellitbilderna är mellan 10 och 60 meter, vilket ger en översiktlig helhetsbild över landskaps vitalitet. Den funktionen lämpar sig för att identifiera utsatta områden, inom vilka man kan ta kompletterande flygbilder med högre upplösning för noggrannare analys. På bilder på bestånd- och fastighetsnivå går det att se vilka områden som är mest drabbade vilket gör att avverknings- och bortforslingsarbetet kan fokuseras. Ur ett skogsskötselperspektiv vill man veta var och i vilken omfattning döda träd finns för att kunna anpassa skötseln. Enligt skogsvårdslagen (SFS 1979:429) ska döda träd lämnas av hänsyn, men vid tillfällen då större partier har dött gäller i stället att markens produktionsförmåga ska tas tillvara, vilket kräver avverkning och bortforsling av döda stammar för att möjliggöra återbeskogning (Skogsstyrelsen 2025). Partier av döda granar som dött på grund av barkborreangrepp kan enligt Granström¹ delvis påverka ett områdes brandkänslighet, i och med att de bidrar med bränsle i en potentiell brand. Det gäller specifikt på längre sikt när avbrutna grenar och kvistar faller till marken som förna. Det som däremot motverkar brandrisken är att nedfallet av döda barr i hög grad kväver markskiktet vilket minskar dess potential som bränsle, och att det ökade ljusinsläppet till marken gynnar ett fålskikt av gräs och örter, vilka är olämpliga som bränsle (Lind et al. 2022).

Ett annat potentiellt användningsområde för detektering av döda träd är som underlag för riskanalys runt infrastruktur. I tätortsnära skogar och välbesökta rekreationsskogar kan döda träd utgöra en säkerhetsrisk i de fall de står nära stigar, vägar eller hus, vilket utgör skäl att plocka bort dem (FSC 2020). Att ha tillgång till detaljerad information om var döda träd står underlättar och effektiviserar arbetet med att plocka bort potentiellt farliga träd, enligt Stereńczak et al. (2017). Platsdata för varje dött träd tillsammans med trädhöjd möjliggör att utföra riskanalyser som kan underlätta rensningsarbete.

Enligt Sylvain et al. (2019) är det svårt att få fram tillförlitlig data om hur mycket död ved som står i skogen eftersom mängden varierar mycket både geografiskt och tidsmässigt. Denna variation gör mängden svår att beräkna med stickprov och statistiska metoder. För att få en god helhetsbild över större områden krävs ett stort antal provytor och noggrann inventering, vilket är både tidskrävande och kostsamt. Sådana inventeringar resulterar i ett medelvärde av död ved inom ett område eller region men visar inte de döda trädens geografiska fördelning, vilket minskar möjligheten att utvärdera skötselstrategier och jämföra mönstret med andra variabler.

För att komma ifrån dessa problem används i allt större utsträckning fjärranalys för att övervaka och insamla information om skogen. Samtidigt har de senaste decennierna sett en snabb utveckling inom maskininlärning som kunnat

¹ Anders Granström, forskare vid SLU, 2025-04-14

implementeras inom många områden (Saha och Ahmad 2025). Dessa avancerade djupinlärningsmodeller kan med hög träffsäkerhet tolka data och identifiera objekt utifrån bilder på ett sätt som efterliknar hur det mänskliga ögat och hjärnan jobbar. Maskininlärningsmodellerna kan hantera data på andra våglängder än det mänskliga ögat kan uppfatta, såsom infrarött ljus. Speciellt infrarött ljus är mycket användbart när man studerar vegetation och dess vitalitet eftersom klorofyll i blad och barr absorberar mycket av det röda ljuset i det synliga spektret men reflekterar det mesta av det infraröda ljuset (Catalão et al. 2022). Döda och stressade växter absorberar däremot mer infrarött ljus än frodig växtlighet gör. Genom att mäta skillnaderna i reflektans kan man bedöma aktiviteten fotosyntes hos vegetationen som studeras. Svårigheten med att använda direkta spektralvärden är att de varierar med ljusförhållandena och påverkas av ljusets infallsvinkel, skuggor och atmosfärens påverkan. Färgåtergivningen för samma typ av växtlighet kan variera på bilder tagna olika dagar eller klockslag. För att komma förbi det problemet används normaliserade spektralvärden, som beräknas genom att kombinera olika våglängdsband och deras skillnader i reflektans. Sådana normaliserade värden kallas vegetationsindex (Eklundh et al. 2020). Ett vanligt vegetationsindex för att bedöma vegetations hälsa är Normalized Difference Vegetation Index (NDVI), som ger varje rasterpixel ett värde mellan 1 och -1. (Figur 4.) Exempelvis har frodig växtlighet ett värde över ca 0,6 och oorganiska material visar negativa värden (GeoSense 2023; Auravant u.å.). Ett liknande index är Green Normalized Difference Vegetation Index (GNDVI), som kombinerar de gröna och närinfraröda våglängdsbanden och fungerar likadant som NDVI (Figur 5.) (Moon 2024). Med hjälp av flygfoton från både RGB-kamera och närinfraröd kamera kan man därför skilja mellan levande träd och döda (Sylvain 2019; Matejčíková et al. 2024).

Det har gjorts flera studier de senaste åren som har testat olika metoder för att hitta döda träd med hjälp av fjärranalys. Catalão et al. (2022) använde NDVI och GNDVI samt RGI (*Simple Ratio Red/Green Index*) för att detektera individuella korkekar (*Quercus suber*) som dött eller haft sjunkande vitalitet mellan 2018 och 2020. De använde sig av högupplösta satellitbilder med 0,5 m upplösning och studieområdet var gles skog påverkad av bete, så kallad "montado". De uppnådde goda resultat på studieområdet, vilket visar på fördelarna med att använda vegetationsindex, men för att testa en modells robusthet bör den också utvärderas på andra bilddata än modellen tränades på. Matejčíková et al. (2024) jämförde olika metoder för att identifiera döda träd med fjärranalys. Man jämförde resultatet mellan flygbilder och satellitbilder, mellan pixelbaserad klassifikation och objektbaserad klassifikation, samt mellan algoritmerna convolutional neural networks (CNN) och Random Forest (RF). CNN hör till djupinlärningstekniken medan RF är en form av maskininlärning, och båda är vanliga att använda inom bildanalys. Den kombination av metoder som gav det bästa resultatet var

objektbaserad klassifikation med CNN på flygbilder, vilket stödjer säkerheten i dessa metoder. För att modeller för detektering av döda träd ska vara praktiskt användbara bör en redan tränad modell kunna appliceras på olika bilddata, vilket i nuläget är ett forskningsområde som det finns en kunskapslucka inom.

Syftet med denna studie är att träna och utvärdera en djupinlärningsmodell i hur väl den kan detektera stående döda träd från högupplösta flygbilder. De frågeställningar som studien ska svara på är 1) Hur bra går det att detektera döda träd i en högupplöst ortofotomosaik med modell som är lokalt tränad på samma bilddata? och 2) Hur bra presterar den tränade modellen om den appliceras på ett annat område med liknande högupplösta ortofotomosaik.


2. Data och Metod

2.1 Data och dess insamling

2.1.1 Försöksområdena

Området där studiens test- och träningsdata är hämtat från är fastigheten Remningstorp i Skara kommun, Västra Götalands län (lat. 58°27'N, long. 13°40'E). Den ägs av Hildur och Sven Wingquists Stiftelse, förvaltas av Skogssällskapet och används av SLU för skogliga fältförsök. Fastigheten är totalt 1 520 ha varav 1 229 är produktiv skogsmark (Skogssällskapet u.å.).

Validering av modellen gjordes på flygbilder över Asa försökspark i Växjö kommun, Kronobergs län (lat. 57°10'N, long. 14°47'E). Fastigheten ägas av Sveaskog och används av bland annat SLU för fältmätningar och försök. Den totala arealen är 1 013 ha varav ca 900 ha är produktiv skogsmark.



Figur 1. Försökspark Remningstorp (blå punkt) och försökspark Asa (röd punkt).

2.1.2 Flygbilder

Flygbilderna över Remningstorp är tagna i en session den 19 juli 2022, från 1 900 – 2 000 meters höjd. Bildövertäckningen inom flygstråk är 60% och är mellan flygstråk 20%. Kameran som användes var en inbyggd storformatskamera

CH150S 71 mm integrerad i Leica TerrainMapper, och bilderna har 8 cm upplösning i fyra band RGBI (Röd-Grön-Blå-Infraröd)

Flygbilderna över Asa försökspark är alla tagna den 26 juni 2019. Bilderna är tagna med PhaseOne RGB-kamera och PhaseOne NIR-kamera från 800 - 1000 meters höjd. Bildövertäckningen inom flygstråk är 60% och mellan flygstråk är 30%. Upplösningen i bilderna är cirka 6,5 cm.


2.2 Tillvägagångssätt

2.2.1 Tränings- och testdata

Programmet som använts är ArcGIS Pro, version 3.4.2. Det är ett allmänt använt program för att hantera geografisk information och göra analyser. Modellen för detektering av stående döda träd är av typen väglett lärande (*supervised learning*) inom djupinlärningstekniken. Modellen får se punkter som manuellt markerats med vilken klass de tillhör, ”död” eller ”levande”, varefter modellen tränas att klassificera testdata som den inte sett än. Testdatat är alla de döda träden på Remningstorp som inte manuellt klassificerades. Ett set av träningsdata markerades på bilddata från Remningstorp, innehållandes 1 925 döda träd och 757 levande träd. Döda och levande träd identifierades och kategoriserades manuellt på ortofotomosaik i RGB och CIR (figur 1 och 2). Klassen med levande träd användes för att ange vad modellen inte skulle söka efter.



Figur 2. Urklipp ur ortofotomosaik i RGB över Remningstorp visandes levande träd (gröna) och döda träd (vita).



Figur 3. Urklipp ur ortofotomosaik i CIR över Remningstorp visandes levande träd (röda) och döda träd (vita).


2.2.2 Vegetationsindex

Av flygbilderna över Remningstorp och Asa skapades raster med vegetationsindex NDVI och GNDVI. Ur ortofotomosaikerna extraherades ett grönt, rött och NIR-band. Dessa kombinerades till två enbandsraster enligt formlerna:


$$NDVI = \frac{NIR - r\ddot{o}d}{NIR + r\ddot{o}d}$$

$$GNDVI = \frac{NIR - gr\ddot{o}n}{NIR - gr\ddot{o}n}$$

Dessa två enbandsraster kombinerades f r att skapa ett tv bandsraster.



Figur 4. Urklipp ur ortofotomosaik i NDVI  ver Remningstorp. Se klustret av d da tr d (ljuslila) i nedre kanten i den r da ringen.



Figur 5. Urklipp ur ortofotomosaik i GNDVI över Remningstorp. Se klustret av döda träd (ljusröda) i nedre kanten i den blåa ringen.

2.2.3 Skapa modell

Målet var att skapa en objektidentifieringsmodell för att detektera stående döda träd i bilddatan över Remningstorp och Asa. Modellen använder sig av objektbaserad klassning där varje träd identifieras och därefter klassas som dött eller ej. Till skillnad från pixelbaserad klassning tas hänsyn till inte bara pixelvärden utan också kronans struktur. Pixelbaserad klassifikation används vanligen på satellitbilder med låg upplösning medan objektbaserad klassifikation är lämplig på flygfoton med tillräcklig upplösning för att urskilja separata objekt (Matejčíková et al. 2024 se Kuželka & Surový 2017).

Modellen skapades i ArcGISs djupinlärningsverktyg i tre steg: förbereda träningsdata; träna modellen; tillämpa modellen. Efteråt sorterades alla identifierade objekt på marknivå bort.

Första steget var att förbereda träningsdata för djupinlärning, med manuellt framtaget träningsdata på Remningstorp och tvåbandsrastret innehållande NDVI och GNDVI över Remningstorp, skapades ett set med träningsdata. De inställningarna som användes vid skapandet av träningsdata var: bufferradie (*buffer radius*) 25 pixlar, rutstorlek (*tile size*) 256x256 pixlar, steglängd (*stride*) 128x128 pixlar och en rotationsvinkel på 45 grader. Formen på metadata som exporterades var PASCAL visual object classes.

Andra steget var att träna djupinlärningsmodellen, vilket gjordes på fastigheten Remningstorp. Det exporterade träningsdatat från första steget tillsammans med tvåbandsrastret innehållande NDVI och GNDVI utgjorde grunden för

djupinlärningsmodellen. Algoritmen för djupinläring som användes var Faster R-CNN som både hittar vad och var objekt finns i en bild. Ett inbyggt nätverk föreslår områden i bilden där objekt kan finnas. Områdena analyseras sedan noggrant för att bestämma objektets typ och till sist markeras de funna objekten med rutor (Esri Developer u.å. se Ren et al.). De inställningar som användes vid skapande av modellen: Max Epoker (*Max Epochs*) 70.


Tredje steget var att identifiera objekt med djupinläring. Objektidentifieringen genomfördes på både Asa och Remningstorp. Modellen som skapades i steg två applicerades på tvåbandsrastret över Asa och Remningstorp med uppdrag att endast identifiera döda träd. De inställningar som användes var: Objekt av intresse (*Objects of Interest*), Döda träd, tröskelvärde (*Threshold*) 0,2. Icke-maximal undertryckning (*Non-Maximum Supression*) användes för att ta bort dubletter, alltså samma objekt som markerats två gånger. Modellen identifierade 21 945 objekt som döda träd på Asa och 10 499 objekt på Remningstorp.

Avslutningsvis sattes en höjdrestriktion på fem meter över marken i syfte att sortera bort falska resultatpunkter som registrerats som döda träd, exempelvis stenar, vägar, bilar och hustak. Två set med höjddata hämtades från Lantmäteriet för Remningstorp och Asa. Det första var Ytmodell 0,5 m latest (laz) Digital Surface Model som beskriver vad som syns från luften med höjdsatta punkter från flygbildsmatchning (Lantmäteriet u.å). Den andra var Markhöjdmodell grid 1+ latest (tif) Terrain Model, vilket är en terrängmodell i gridformat med koordinatsatta höjdpunkter (Lantmäteriet u.å). Höjdkorrigeringen gjordes genom att subtrahera ytmodellen från markhöjdsmodellen över respektive område. De punkter som befann sig under 5 meter över markytan sorterades bort ur resultatlistan. Höjdkorrekturen genomfördes på både Asa och Remningstorp.

2.2.4 Validering

Modellen validerades först lokalt på en ortofotomosaik över Remningstorp och därefter externt på ortofotomosaiken över Asa försökspak. Som stickprov lades 400 provtytor med 20 meters radie slumpmässigt ut över varje område. I varje provyta granskas alla träd manuellt, och alla träd som identifierats som döda (*true positive*) räknas. Dessutom räknas alla döda träd som modellen inte lyckats identifiera (*false negative*), samt alla levande träd som felaktigt klassificerats som döda (*false positive*) (Bilaga 1). I bilddatan ingick andra ägoslag än skog, exempelvis bebyggelse, ängar och vatten, men bara provytorna som innehöll träd räknades. I ortofotomosaiken över Remningstorp togs alla träd som markerats som träningsdata bort.

Tabell 1. Exempel på identifierade objekt vid detektion av döda träd på Remningstorp och Asa. Provytor gul färg och objekt identifierade av djupinlärningsmodellen är i rosa färg.

	Remningstorp	Asa
Representativ provyta,		
Exempel på objekt djupinlärningsmodellen har identifierat		

Precision anger hur stor andel av de markerade punkterna som faktiskt är döda träd, och träfffrekvens visar hur stor andel av alla döda träd som modellen lyckats identifiera. F1-poäng väger samman precision och träfffrekvens för att redovisa det sammantagna resultatet. I denna studie förekommer både att modellen inte identifierat faktiskt döda träd och att den felaktigt markerat levande träd som döda, och därför redovisar F1-poäng det mest rättvisa resultatet.

$$Precision = \frac{True\ Positive}{True\ Positive + False\ Positive}$$

$$Träfffrekvens = \frac{True\ Positive}{True\ Positive - False\ Negative}$$

$$F1 - poäng = \frac{2 * Precision * Recall}{Precision + Recall}$$

3. Resultat

53 av de 400 provvytorna på ortofotomosaiken över Remningstorp innehöll antingen markerade träd eller döda träd och användes i uträkningen av resultatet. Av de 400 provvytorna på ortofotomosaiken över Asa räknades 256 bort som inte innehöll några träd av intresse, och kvar blev 144 provvytor.

Tabell 2. Redovisat resultat för provvytor i valideringen för fastigheterna Remningstorp och Asa. Resultats som redovisas; är antal relevanta provvytor alltså provvytor som innehåller objekt av intresse. True positiv, False Negativ och False Positiv.

Fastighet	Provytor	Antal relevanta provvytor	True Positiv	False Negativ	False Positiv
Remningstorp	400	53	52	14	13
Asa	400	144	21	277	95

Tabell 2 redogör en tydlig skillnad i antalet träfffrekvensnoteringar gjorda över de två försöksområdena. På Remningstorp gjordes totalt 79 noteringar i 53 provvytor varav 52 var korrekt identifierade döda träd (true positives) och 27 felaktiga detekteringar (14 false negatives och 13 false positives). På Asa gjordes 393 noteringar i 144 provvytor, varav endast 21 var korrekta (true positives) och 372 var felaktiga (277 false negatives och 95 false positives).

Tabell 3. Resultat av validering för fastigheterna Remningstorp och Asa. Tabellen redovisar resultat i precision, träfffrekvens och F1-poäng.

Fastighet	Precision	Träfffrekvens	F1-poäng
Remningstorp	0,8	0,79	0,79
Asa	0,18	0,08	0,12

Tabell 3 sammanfattar modellens precision, träfffrekvens och F1-poäng över försöksområdena Remningstorp och Asa. F1-poäng kombinerar precision och träffsäkerhet, vilket ger ett balanserat mått på hur väl modellen presterade. Remningstorp fick 0,79 F1-poäng vilket är 0,67-F1poäng mer än Asas 0,12 F1-poäng.

4. Diskussion

Syftet med denna studie har varit att bygga, träna och applicera en djupinlärningsmodell för detektion av döda träd på en högupplöst ortofotomosaik, utvärdera modellens träffsäkerhet att korrekt detektera döda träd lokalt på Remningstorp, det vill säga från samma ortofotomosaik som modellen tränats på, samt att jämföra modellens träffsäkerhet på en liknande mosaik över Asa försökspark, 160 km bort. Modellen tränades på träningsdata från bilddata över Remningstorp, vilket gav tillfredställande resultat. När samma modell applicerades på ortofotomosaiken över Asa så presterade modellen avsevärt sämre, trots att bilddatan var jämförbar i upplösning och kvalitet. Resultatet på Remningstorp var 0,79 F1-poäng medan från Asa var bara 0,12 F1-poäng. I valideringen lades 400 provytor ut över varje område, men få av dem innehöll någon relevant data. Det visar på hur svårt och tidskrävande det är att samla in information om död ved eftersom mängden är mycket liten jämfört med antalet levande träd i de flesta brukade skogar.

Fastigheterna som använts som underlag ligger båda i södra Sveriges hemiboreala zon och består till stor del av granskog med vissa inslag av lövträd. De har båda en historik av olika typer av skogliga fältförsök vilket kan ha gjort att de skiljer sig från och därmed inte är helt representativa för övrig brukad skog i regionen. Remningstorp har en högre andel döda träd vilka ofta står samlade i kluster, troligtvis dödade av de senaste årens granbarkborreutbrott. Detta borde inte påverka resultatet från Asa eftersom modellens arbetsmetod är att dela upp ortofotomosaiken i rutor som granskas oberoende av varandra. Av de identifierade träden i Remningstorp kan ses att modellen har svårt att hitta döda träd omgivna av andra i ett kluster. Det kan bero på att kontrasten mellan levande och död biomassa hjälper modellen att identifiera individuella döda träd (se bilaga 1).

Modellen är utvärderad mot valideringsdata som tagits fram manuellt från högupplösta flygbilder, då det inte varit möjligt att inom studiens omfattning samla in fältdata. Ett krav på flygbilder för sådan här analys är att de måste vara tagna efter lövsprickning, dock innan löven faller på hösten. För att manuellt kunna validera resultatet så måste det gå att skilja mellan döda träd och avlövade lövträd (Krzystek et al. 2020).

En svårighet i analysen var skillnaden i radiell höjddeplacering i ortofotomosaikerna mellan Asa och Remningstorp. Bilddatan som modellen tränades på är nära ett sant ortofoto där alla träden ses nästan rakt ovanifrån, men på bilden från Asa framstår det som om många träd lutar. Det beror på skillnad i proportionen mellan flyghöjd och storleken på området på marken som omfattas i varje enskild flygbild som bygger upp ortofotomosaiken. Trots liknande överlapp mellan flygbilderna så gör den lägre flyghöjden från överflygningen över Asa att vissa träd fotograferats i snedvinkel. Den synbara lutningen gjorde att på vissa

träd syntes både kronan och stammen, vilket gjorde att modellen ibland identifierade stammen på ett levande träd som ett dött träd (bilaga 1). Modellen är tränad på att identifiera trädkronor ovanifrån och skillnaden i bildkvalitet kan ha bidragit till de sämre resultaten från Asa.

En höjdrestriktion lades på de datapunkter som modellen hittade för att sortera bort icke-levande objekt som inte är döda träd. Gränsen lades på 5 meter över marken vilket gjorde att många felaktiga punkter föll bort och resultatets träffsäkerhet förbättrades. Nackdelen är att det kan ha gjort att delvis avbrutna stående stammar och högstubbar inte kom med i resultatet. De uppfyller ofta samma ekologiska funktioner som fullstora stammar men finns inte redovisade i vårt resultat. Det är möjligt att sådana låga stammar finns på undersökningsområdena men som inte syns på flygbilder, då de står under krontaket i slutna bestånd. Enligt Mäyrä et al. (2025) kan bara 60% av stående död ved ses på bilder tagna från drönare med 3,9 till 4,4 cm upplösning, högre än den som använts i denna studie. Höjdrestriktionen används för att i högre grad identifiera döda träd i höjd med eller över omgivande trädkronor, medan svagheten blir att hitta död ved under krontaket.

Vårt resultat kan jämföras med det av Catalão et al. (2022) som fick en precision på 94%, träfffrekvens på 92% och en F1-poäng på 93% i detektering av döda träd på området som deras modell tränats på. Men för att verkligen vara användbar borde modellen jämföras inte bara med manuell validering på flygfoton utan också med fältdata för att garantera kopplingen till skogarnas verkliga tillstånd. Fjärranalytiska metoder kan än så länge inte helt ta över fältinventeringarnas roll och få fullgott dataunderlag, utan kan användas som ett komplement till dessa. Därför bör sådan här fjärranalys av död ved kompletteras med fältdata för att på bästa sätt avgöra antal förekomster av död ved.

5. Slutsatser

Avslutningsvis har denna studie undersökt och utvärderat hur väl en tränad djupinlärningsmodell kan detektera döda träd på samma ortofotomosaik den tränades på, vilket visade sig fungerade mycket bra med en F1-poäng på 0,79. Studien undersökte även hur väl samma modell kan detektera döda träd på ett annan bilddata än den tränades på, detta gav ett avsevärt sämre resultat med 0,12 F1-poäng. Detta tyder på att modellen har svårt att generalisera till nya miljöer, men genom användning av överförande lärande (*transfer learning*) skulle en robustare modell med större möjlighet för geografisk förflyttning kunna skapas. Ett framtida användningsområde kan vara att ersätta fältinventering men idag är modellen inte tillräcklig. Att det finns en framtid för denna typ av modeller är väldigt trolig men det kommer krävas mycket robustare modeller som enkelt går att applicera på olika områden för att det ska kunna användas i kommersiellt syfte.

Referenser

- Auravant (u.å.) *Vegetation indices and their interpretation: DNVl, GNDVI, MSAVI2, NDRE, and NDWI*. <https://www.auravant.com/en/articles/precision-agriculture/vegetation-indices-and-their-interpretation-ndvi-gndvi-msavi2-ndre-and-ndwi/> [2025-05-22]
- Catalão, J., Navarro, A. & Calvão, J. (2022). Mapping Cork Oak Mortality Using Multitemporal High-Resolution Satellite Imagery. *Remote Sensing*. 14 (12), 2750. <https://doi.org/10.3390/rs14122750>
- Eklundh, L., Ågrem, J., Olsson, H., Harrie, L. & Klang, D. (2020). Kapitel 4: Insamling av geografiska data. I: Harrie, L. (red.) *Geografisk informationsbehandling: teori, metoder och tillämpningar*. Studentlitteratur. 85-127.
- Esri Developer (u.å.) *Faster R-CNN Object Detector*. [Faster R-CNN Object Detector | ArcGIS API for Python](https://www.esri.com/arcgis/api/python/) [2025-05-22]
- FSC (2020). FSC-standard för skogsbruk i Sverige. <https://se.fsc.org/se-sv/regler/skogsbruksstandard> [2025-04-14]
- GeoSense (2023). *10 Common Vegetation Indices and Their Applications in Remote Sensing*. <https://geosense.substack.com/p/10-common-vegetation-indices-and> [2025-04-10]
- Murel, J. & Kavlakoglu, E. (2024). *What is transfer learning?* [What is transfer learning? | IBM](https://www.ibm.com/cloud/what-is-transfer-learning/) [2025-05-23]
- Jonsson, B.G., Ekström, M., Esseen, P.-A., Grafström, A., Ståhl, G. & Westerlund, B. (2016). Dead wood availability in managed Swedish forests – Policy outcomes and implications for biodiversity. *Forest Ecology and Management*. 376, 174–182. <https://doi.org/10.1016/j.foreco.2016.06.017>
- Krzystek, P., Serebryanyk, A., Schnörr, C., Červenka, J. & Heurich, M. (2020). Large-Scale Mapping of Tree Species and Dead Trees in Šumava National Park and Bavarian Forest National Park Using Lidar and Multispectral Imagery. *Remote Sensing*. 12 (4), 661. <https://doi.org/10.3390/rs12040661>
- Kuželka, M. & Surový, P. (2017). *Systém Operativního Leteckého Snímkování pro Doplnování Ortofotografií po Hospodářských Zásazích Nebo po Kalamitách*. Česká Zemědělská Univerzita v Praze: Brno, Czech Republic; ISBN 978-80-213-2811-3.
- Lantmäteriet (u.å.) *Markhöjdmodell Nedladdning, grid 1+*. [Markhöjdmodell Nedladdning, grid 1+ | Lantmäteriet](https://www.lantmateriet.se/Markhojdmodell/Nedladdning-grid-1/) [2025-05-22]
- Lantmäteriet (u.å.) *Ythöjdmodell Nedladdning, från flygbilder*. [Ythöjdmodell Nedladdning, från flygbilder | Lantmäteriet](https://www.lantmateriet.se/Ythojdmodell/Nedladdning-fran-flygbilder/) [2025-05-22]
- Lind, T., Butler, A., Granström, A., Wiström, B. & Holmström, H. (2022). *Alternativa skötselstrategier i tätortsnära skog: En framtidsanalys för Sundsvalls kommun*. (2022:1) SLU. <https://www.slu.se/globalassets/ew/org/andra-enh/s/forskning/rapportserie/rapport-skog-2022-1-lind-web.pdf> [2025-04-16]

- Löfroth, T., Birkemoe, T., Shorohova, E., Dynesius, M., Fenton, N.J., Drapeau, P. & Tremblay, J.A. (2023). *Deadwood Biodiversity*. I: Montoro Girona, M., Morin, H., Gauthier, S. & Bergeron, Y., (red.) *Boreal Forests in the Face of Climate Change*. Springer. 167 – 189. ISBN 978-3-031-15990-9.
- Matejčíková, J., Věbrová, D. & Surový, P. (2024). Comparative Analysis of Machine Learning Techniques and Data Sources for Dead Tree Detection: What Is the Best Way to Go? *Remote Sensing*. 16 (16), 3086. <https://doi.org/10.3390/rs16163086>
- Moon, G. (2024). Optimizing Vegetation Index Calculations: The GNDVI Approach. *Deepblock*. [Blogg]. 2024-06-03. <https://www.deepblock.net/blog/gndvi> [2025-05-23]
- Mäyrä, J., Tanhuanpää, T., Kuzmin, A., Heinaro, E., Kumpula, T. & Vihervaara, P. (2025). *UAVs and deep learning can enhance the mapping of deadwood in boreal forests*. [Opublicerat manuskript]
- Saha, S. & Ahmad, T. (2025). Chapter 2 – A basic introduction to deep learning. I: Saha, S. (red.) *Deep Learning for Multi-Sensor Earth Observation*. Elsevier Ltd. 19 – 49. <https://doi.org/10.1016/B978-0-44-326484-9.00010-5>
- SFS 1979:429. *Skogsvårdslag*. Landsbygds- och infrastrukturdepartementet.
- Skogsstyrelsen (2021). *Skogsskador i Sverige 2020*. (2021/702) Skogsstyrelsen. <https://www.skogsstyrelsen.se/globalassets/nyheter/skogsstyrelsens-nationella-skogsskaderapport-2020.pdf>
- Skogsstyrelsen (2025). *Så hanterar du döda granskogar*. <https://www.skogsstyrelsen.se/bruks-skog/skogsskador/insektsskador/granbarkborre/sa-hanterar-du-doda-granskogar/> [2025-05-11]
- Skogsstyrelsen, SLU (2025). *Förändringsanalys för att följa angreppen av granbarkborre*. <https://skogsdatalabbet.se/forandringsanalys-for-att-folja-angreppen-av-granbarkborre/#:~:text=Nationellt%20skogsdatalabb%20kan%20erbjuda%20en%20analys%20p%C3%A5%20data,gjort%20att%20behovet%20av%20en%20s%C3%A5dan%20t%C3%A4nst%20%C3%B6kat>. [2025-05-07].
- Skogssällskapet (u.å.) *Hildur & Sven Wingquists stiftelse för skogsvetenskaplig forskning – Stiftelsens uppgift och funktion*. <https://www.skogssallskapet.se/narstaende-stiftelser/hildur--sven-wingquists-stiftelse-for-skogsvetenskaplig-forskning.html> [2025-04-27]
- SKSFS 2025:2. *Skogsstyrelsens föreskrifter och allmänna råd om förebyggande av växtskadegörare för skydd av skog*. Skogsstyrelsen
- SLU (2022) *Asa*. <https://www.slu.se/institutioner/skoglig-faltforskning/forsoksparker/asa-forsokspark/> [2025-04-27]
- SLU Artdatabanken (2025a) *Sök och filtrera*. <https://artfakta.se/sok/taxa?redlistCategories=%5B0,1,2,3,4,5%5D&landscapeTypes=%5B662%5D&landscapeImportant=false&substrates=%5B2459%5D&substrateImportant=false> [2025-04-14]


- SLU Artdatabanken (2025d). *Artfakta: aspborre (Trypophloeus binodulus)*.
<https://artfakta.se/taxa/101937> [2025-04-14]
- SLU Artdatabanken (2025c). *Artfakta: granbock (Monochamus sartor)*.
<https://artfakta.se/taxa/101341> [2025-04-14]
- SLU Artdatabanken (2025b). *Artfakta: tretåig hackspett (Picoides tridactylus)*.
<https://artfakta.se/taxa/100109> [2025-04-14]
- SLU Riksskogstaxeringen (2024). *Skogsdata 2024*
https://www.slu.se/globalassets/ew/org/centrb/rt/dokument/skogsdata/skogsdata_2024_web.pdf
- Stereńczak, K., Kraszewski, B., Mielcarek, M. & Piasecka, Z. (2017). Inventory of standing dead trees in the surroundings of communication routes: The contribution of remote sensing to potential risk assessments. *Forest Ecology and Management*. 402 (2017), 76–91.
- Sylvain, J.D., Drolet, G. & Brown, N. (2019). Mapping dead forest cover using a deep convolutional neural network and digital aerial photography. *Journal of Photogrammetry and Remote Sensing*. 156 (2019), 14-26
<https://doi.org/10.1016/j.isprsjprs.2019.07.010>
- Södra (u.å.). *Naturvärdesbedömning*. [PDF] [2025-05-12]
- Tuia, D., Volpi, M., Lagrange, A., Marmanis, D., Camps-Valls, G. & Bruzzone, L. (2023). Transfer learning in environmental remote sensing. *Remote Sensing of Environment*. 294, 113605.
<https://www.sciencedirect.com/science/article/abs/pii/S0034425723004765>

Bilaga 1. Exempelbilder från Remningstorp och Asa

Bildexempel från Remningstorp och Asa.

Tabell 4. Exempelbilder från Remningstorp och Asa. Gul färg indikerar provytor och rosa färg identifierade objekt.

Kommentar	Remningstorp	Asa
Provytor utan funna objekt		
True Positive, döda träd som korrekt identifierats som döda träd av modellen.		
False Positive, levande träd som felaktigt identifierats som döda av modellen.		

False Negativ, döda träd som modellen missat att markera.		
Kluster av döda träd		
Representativa provtytor		
Exempelbilder som påvisar hur ortofoto- mosaiken får det att se ut som träden lutar.		

Skogliga försök, båda fastigheterna är försöksparker för skogliga fältförsök.		
--	---	--

Publicering och arkivering

Godkända självständiga arbeten (examensarbeten) vid SLU kan publiceras elektroniskt. Som student äger du upphovsrätten till ditt arbete och behöver i sådana fall godkänna publiceringen. I samband med att du godkänner publicering kommer SLU även att behandla dina personuppgifter (namn) för att göra arbetet sökbart på internet. Du kan närsomhelst återkalla ditt godkännande genom att kontakta biblioteket.

Även om du väljer att inte publicera arbetet eller återkallar ditt godkännande så kommer det arkiveras digitalt enligt arkivlagstiftningen.

Du hittar länkar till SLU:s publiceringsavtal och SLU:s behandling av personuppgifter och dina rättigheter på den här sidan:

- <https://libanswers.slu.se/sv/faq/228316>

Alla författare till arbetet måste kryssa i sitt godkännande. Ta bort eller lägg till rader beroende på antalet författare. Ta bort den här texten när den inte längre behövs.

☒ JA, jag, Vera Persson har läst och godkänner avtalet för publicering samt den personuppgiftsbehandling som sker i samband med detta

☒ JA, jag, Saga Stålhandske har läst och godkänner avtalet för publicering samt den personuppgiftsbehandling som sker i samband med detta

☐ NEJ, jag/vi ger inte min/vår tillåtelse till att publicera fulltexten av föreliggande arbete. Arbetet laddas dock upp för arkivering och metadata och sammanfattning blir synliga och sökbara.