



Bildigenkänning för bättre val av planteringspunkter vid maskinell plantering

Image recognition for better choice of planting spots in mechanized tree planting

Alice Kårehagen

Examensarbete/Självständigt arbete • 30 hp

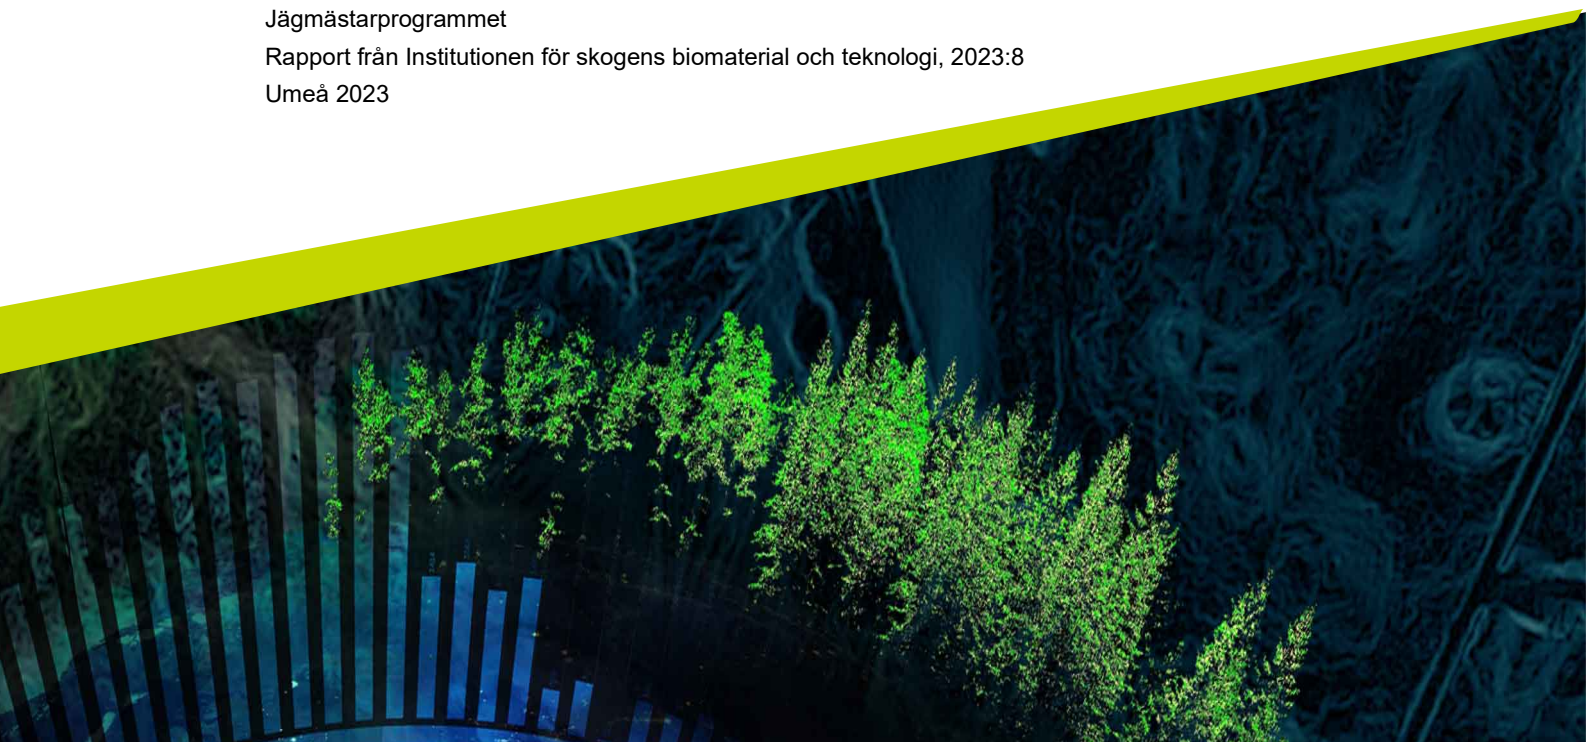
Sveriges lantbruksuniversitet, SLU

Skogens biomaterial och teknologi

Jägmästarprogrammet

Rapport från Institutionen för skogens biomaterial och teknologi, 2023:8

Umeå 2023



Bildigenkänning för bättre val av planteringspunkter vid maskinell plantering

Image recognition for better choice of planting spots in mechanized tree planting

Alice Kårehagen

Handledare: Tomas Nordfjell, Sveriges lantbruksuniversitet, Institutionen för skogens biomaterial och teknologi
Bitr. handledare: Sara Nilsson, Holmen skog
Examinator: Dan Bergström, Sveriges lantbruksuniversitet, Institutionen för skogens biomaterial och teknologi

Omfattning: 30 hp
Nivå och fördjupning: Avancerad nivå A2E
Kurstitel: Masterarbete i skogsvetenskap
Kurskod: EX0956
Program/utbildning: Jägmästarprogrammet
Kursansvarig inst.: Institutionen för skogens biomaterial och teknologi
Utgivningsort: Umeå
Utgivningsår: 2023
Upphovsrätt: Alla bilder används med upphovspersonens tillstånd.
Serietitel: Rapport från Institutionen för skogens biomaterial och teknologi
Delnummer i serien: 2023:8

Nyckelord: maskinseende, Plantma X, multiclass classification, artificiell intelligens

Sveriges lantbruksuniversitet
Fakulteten för skogsvetenskap
Institutionen för skogens biomaterial och teknologi

Sammanfattning

Minskande arbetskraft för manuell plantering i Sverige har bidragit till ett ökat intresse för mekaniserad plantering. För att uppnå en lönsamt hög produktivitet för kontinuerligt framryckande planteringsmaskiner krävs en förbättring av deras förmåga att identifiera lämpliga planteringspunkter. Syftet med denna studie var att utvärdera hur väl ett nyligen framtaget bildigenkänningsverktyg bedömer planteringspunkters lämplighet att planteras jämfört med en manuell plantörs bedömning. Verktyget bedömer sannolikhet för om en punkt domineras av *Mineraljord*, *Humus* och *Ej planterbart*. Ett delsyfte var att studera vilka tröskelvärden för de bedömda faktorerna som ger högsta överensstämmelsen under olika förhållanden. Studien genomfördes på fyra nyligen markberedda områden som dominerades av morän. Det studerade verktyget består av ett AI system som bygger på bildanalys genom *multiclass classification*. På 420 slumpvis valda punkter togs fotografier, en del både i skugga och solsken. Som referens utfördes en fältbedömning enligt instruktioner för uppföljning av manuell plantering för respektive punkt. Fotografierna analyseras sedan av bildigenkänningsverktyget.

Resultatet visade att under mulna väderförhållanden har verktyget förmågan att i 83,8 % av fallen bedöma i enlighet med fältbedömning. Soliga ljusförhållanden gav signifikant påverkan på prediktionerna av klasserna *Humus* och *Ej planterbart* och sämre överensstämmelse. Klasserna *Mineraljord* och *Ej planterbart* visades vara lämpligast att användas som tröskelvärden. Optimala tröskelvärden varierade mellan trakterna men låg generellt på minst 40-50 % *Mineraljord* och högst 10 % *Ej planterbart*.

Slutsatser av studien är att det är möjligt att använda bildigenkänningsverktyg för att undvika merparten av dåliga planteringspunkter. Slutsatsen är också att det studerade bildigenkänningsverktyget är ett steg på vägen men att fortsatt utvecklingsarbete krävs för att fungera bättre i solsken.

Nyckelord: artificiell intelligens, maskininlärning, maskinseende, multiclass classification, Plantma X

Abstract

Decreasing workforce for manual planting in Sweden has contributed to an increased interest in the development of mechanized planting. To achieve profitable high productivity for continuously advancing planting machines an improvement in the ability to identify suitable planting spots is required. The aim of this study was to evaluate how well a newly developed image recognition tool's assessment of planting spots suitability to be planted corresponds to a manual planter's assessment. The tool assesses the probability of a planting spot being dominated by *Mineral soil*, *Humus* and *Not plantable*. A sub-aim was to study which threshold values for the assessed factors results in the highest agreement under various conditions. The study was conducted on four recently soil prepared sites that were dominated by moraine. The studied tool consists of an AI system based on image analysis through *multiclass classification*. At 420 randomly selected spots photographs were taken, some in both shade and sunshine. As a reference, a field assessment of each spot was carried out according to instructions for evaluation of manual planting. The photographs were then analysed by the image recognition tool.

The result showed that under overcast weather conditions, the tool can assess in accordance with field assessment in 83.8 % of cases. Sunny light conditions had a significant impact on the predictions of the classes *Humus* and *Not plantable* and decreased the agreement. The classes *Mineral soil* and *Not plantable* were shown to be the most suitable to use as threshold values. Optimal threshold values varied between the sites but were generally at least 40-50 % *Mineral soil* and at most 10 % *Not plantable*.

The conclusions of the study are that it is possible to use image recognition tools to avoid the majority of bad planting points. The conclusion is also that the studied image recognition tool is a step on the way, but further development is required for better function in sunlight.

Keywords: artificial intelligence, machine learning, machine vision, multiclass classification, Plantma X

Förord

Denna studie är ett examensarbete omfattande 30hp på avancerad nivå genomförd vid Institutionen för skogens biomaterial och teknologi på Sveriges lantbruksuniversitet i Umeå.

Jag vill rikta ett stort tack till min handledare Tomas Nordfjell som genom stort engagemang varit ett viktigt stöd under arbetets gång.

Jag vill också tacka Holmen Skog och Sara Nilsson som givit mig möjligheten att genomföra detta examensarbete och varit till stor hjälp under fältarbetet. Ett stort tack även till Skogforsk och Jan Johansson som bidragit med viktig kunskap om ämnet och hjälp vid genomförandet av bildanalyserna.

Till sist så vill jag även tacka min familj och vänner för deras stöd.

Umeå, mars 2023
Alice Kårehagen

Innehållsförteckning

1.	Inledning	13
1.1	Markberedning och plantering av skog i Sverige	13
1.1.1	Den ideala planteringspunkten	14
1.2	Maskinell plantering	14
1.2.1	Plantma X	15
1.2.2	Tidigare studier av Plantma X	17
1.3	AI och maskinseende	17
1.3.1	Multiclass classification och andra tekniker	18
1.3.2	Bildigenkänningsverktyg för Plantma X	18
1.4	Syfte	20
1.5	Avgränsningar	20
2.	Material och Metod	21
2.1	Studieområde	21
2.2	Datainsamling	22
2.2.1	Utläggning av provtytor	22
2.2.2	Bildinsamling	22
2.2.3	Manuell fältbedömning av planteringspunkt	23
2.2.4	Traktförhållanden	24
2.2.5	Bearbetning och analys av bilder	25
2.3	Analys och statistik	26
3.	Resultat	29
3.1	Utvärdering av prediktionsklasser	29
3.1.1	Prediktion vid mulna väderförhållanden	29
3.1.2	Jämförelse av prediktioner i sol och skugga	32
3.2	Tröskelvärden för <i>Mineraljord</i> och <i>Ej planterbart</i> för bästa överensstämmelse med fält-bedömningar	36
3.2.1	Optimala tröskelvärden för alla trakter tillsammans i mulet väder	36
3.2.2	Optimala tröskelvärden per trakt	37
3.2.3	Prediktionsklassen <i>Ej planterbart</i> - Överensstämmning med fältbedömning ..	38
3.3	Jämförelse av överensstämmelse i spår och tilla i mulet väder	39
3.3.1	Alla trakter tillsammans	39
3.3.2	Skillnader mellan trakter	40

3.4	Effekt av ljusförhållanden	41
3.4.1	Tröskelvärden och solsken	41
4.	Diskussion	43
4.1	Resultatdiskussion	43
4.2	Metoddiskussion	46
4.3	Fortsatta studier	47
4.4	Förbättringspotential genom kombination med mekanisk avkänning av hinder	48
4.5	Slutsatser	49
	Referenser.....	51
5.	Bilaga	54

Tabellförteckning

Tabell 1. Traktegenskaper för trakter använda vid datainsamling av bilder. Grundförhållande, ytstruktur, och lutning (GYL), höjd över havet och vegetationstyp för hela trakten enligt Holmens beståndsregister. Jordart och markfuktighet enligt fältbedömningar inom försöksyta	21
Tabell 2. Beskrivning av planteringspunktsklasser enligt Holmens uppföljningsinstruktion för manuell plantering	24
Tabell 3. Parametrar för konstruktion av ROC (Receiver Operator Characteristic) - kurva	27
Tabell 4. Median, medelvärde, standardavvikelse och p-värde av Wilcoxon signed-rank test för differenserna i bildigenkänningverktygets prediktering för respektive klass i de olika ljusförhållandena. Signifikansnivån är $\alpha = 0,0167$ (efter Bonferroni-korrektion). * = signifikant skillnad	35
Tabell 5. Högsta överensstämmelse med Holmen-bedömningen per trakt och motsvarande tröskelvärden för att uppnå dessa. Prediktioner godkänns för plantering om dessa är \geq tröskelvärdet för Mineraljord och \leq tröskelvärdena för Ej planterbart. För vissa trakter ges samma överensstämmelse vid flera olika kombinationer av tröskelvärden.....	37
Tabell 6. Andel överensstämmelse med Holmen-bedömningen per trakt vid användning av optimala tröskelvärden (se 3.2) på klasserna Mineraljord och Ej planterbart för alla trakter tillsammans. Till exempel "M40E0" motsvarar tröskelvärdena Mineraljord 40 % och Ej planterbart 0 %. Högsta värden fetstilta. Prediktioner godkänns för plantering om dessa är \geq tröskelvärdet för Mineraljord och \leq tröskelvärdena för Ej planterbart.....	38
Tabell 7. Högsta överensstämmelse (%) med Holmen-bedömning för respektive trakt och för spår respektive tilla vid användning av prediktioner av klasserna Mineraljord och Ej planterbart som tröskelvärden	40
Tabell 8. Tröskelvärden (%) för klasserna Mineraljord och Ej planterbart för högsta överensstämmelse med Holmen-bedömning per trakt för provytor i tilla respektive spår. Prediktioner godkänns för plantering om dessa är \geq tröskelvärdet för Mineraljord och \leq tröskelvärdena för Ej planterbart. För vissa	

trakter ges samma överensstämmelse vid flertalet kombinationer av tröskelvärden41

Tabell 9. Överensstämmelse med Holmen-bedömningen för respektive ljusförhållande vid användning av optimala tröskelvärden på klasserna Mineraljord och Ej planterbart för provytor vid förhållanden utan sol (se 3.2). Till exempel "M40E0" motsvarar tröskelvärdena Mineraljord 40 % och Ej planterbart 0 % 42

Tabell 10. Överensstämmelse med Holmen-bedömningen vid användning av endast bildigenkänning och användning marksensor och bildigenkänning tillsammans. Marksensorn innebär att provytor i fält bedömda som ej planterbara inte planteras, och provytor bedömda som planterbara blir planterade. Gäller för användning av bildigenkänning med de mest optimala tröskelvärdena för alla trakter tillsammans (M40E0, M40E5, M40E10, M50E0) 49

Figurförteckning

Figur 1. Plantma X planteringsmaskin (Foto: Sara Nilsson, Holmen Skog).....	16
Figur 2. Bildigenkänningsverktygets kamera monterad på Plantma X (Foto: Alice Kårehagen)	19
Figur 3. Uppställning av utrustning för insamling av bilder på provytorna (Foto: Alice Kårehagen).	23
Figur 4. Exempel på originalbild (till vänster) och bild efter att provytan, motsvarande området innanför ramens vita markeringar, blivit utskuren (till höger) (Foto: Alice Kårehagen).	25
Figur 5. ROC (Receiver Operator Characteristic) – kurvor och responderande AUC (Area Under the Curve) för logistiska regressionsmodeller (Figur 6) med respektive prediktionsklass för bildigenkänningsverktyget (Mineraljord, Humus och Ej planterbart) som klassificerare för Holmen-bedömningen. På y-axeln visas andel provytor som enligt fältbedömning är godkända och som klassas som godkända av klassificeringsmodellen (TPP). På x-axeln visas andel provytor som enligt fältbedömning är underkända men som klassas som godkända av klassificeringsmodellen (FPP). En optimal ROC-kurva går från punkt (0, 0) till (0, 100) och från (0, 100) till (100, 100). Den 45° diagonala linjen motsvarar en ROC-kurva då klassningen sker slumpmässigt.....	30
Figur 6. Logistiska regressionsmodeller med de tre prediktionsklasserna Mineraljord (ö.v.), Humus (ö.h.) och Ej planterbart (n.v.) som klassificerare av Holmen-bedömning. Modellerna visar sannolikheten att en provyta bedöms som godkänd baserat på bildigenkänningsverktygets prediktion av respektive klass. Den vågräta grå streckade linjen visar optimalt tröskelvärde för regressionsmodellen och motsvarar det maximala värdet för differensen av True Positive Percentage (TPP) och False Positive Percentage (FPP) i Receiver Operator Characteristic (ROC) - kurvorna. Skärningspunkten är även det optimala tröskelvärdet för prediktionsklassen som enskild klassificerare i bildigenkänningsverktyget (x-axeln).	31
Figur 7. Prediktion i sol (x-axel) plottat mot prediktion i skugga (y-axel) för klasserna Humus (ö.v.), Ej planterbart (ö.h.) och Mineraljord (n.v.). Streckad linje visar	

fullkomlig överensstämmelse av prediktioner i sol och skugga. Prickade linjer visar +/- 20 %-enheter av streckad linje.	33
Figur 8. Låddiagram av differenserna i prediktering för de olika ljusförhållandena för respektive predikteringsklass, Humus (ö.v.), Mineraljord (ö.h.) och Ej planterbart (n.v).....	34
Figur 9. Andel överensstämmande provytor med Holmen-bedömningen (t.v.) respektive enligt Planterbart-bedömningen (t.h.) för olika tröskelvärde-inställningar för klasserna Mineraljord och Ej planterbart.	36
Figur 10. Andel provytor i fält manuellt bedömda som omarkberedda och/eller ej planterbara fördelade på bildigenkänningsverktygets prediktioner (%) av klassen Ej planterbart..	39
Figur 11. Andel överensstämmande provytor med Holmen-bedömningen för provytor i tilla respektive spår vid olika tröskelvärden för klasserna Mineraljord och Ej planterbart.	40

Förkortningar

AI	Artificial Intelligence
AUC	Area Under the Curve
CNN	Convolutional Neural Network
ROC	Receiver Operator Characteristic

1. Inledning

1.1 Markberedning och plantering av skog i Sverige

Plantering är en skogsodlingsmetod som snabbt ger ny etablering av ett bestånd efter slutavverkning och passar att tillämpas på de flesta typer av marker (Hallsby 2013). Dessa fördelar har lett till att plantering idag är den vanligaste metoden för föryngring. Det senaste decenniet har plantering använts som föryngringsmetod på omkring 80 % av föryngringsavverkningarna i Sverige (Skogsstyrelsen 2022a). Majoriteten av de trakter som planteras markbereds också innan för att skapa gynnsammare förhållanden för plantorna. Av de 200 000 ha som planterades under 2021 så har 174 000 ha markberetts maskinellt (Skogsstyrelsen 2022b). De kontinuerligt framryckande metoderna harvning, högläggning och fläckmarkberedning är de vanligaste, men även intermittent framryckande metoder som högläggning med grävskopa förekommer på svårare marker med hög blockighet och andra hinder som stubbar, tjockt humustäcke och avverkningsrester (Skogforsk 2020; Hallsby 2013). Plantering efter markberedning ger säkrare beståndsetablering än plantering utan (Hallsby 2013).

I Sverige utförs majoriteten av planteringarna manuellt av säsongsanställd personal (Hallsby 2013). Idag är det främst utländsk arbetskraft som utför det fysiskt krävande arbetet. En studie från 2019 visar att arbetare från Litauen, Polen, Rumänien och Ukraina stod för 85 % av arbetskraften inom Sveriges 10 största skogsvårdsföretag, och att bara 3 % kom från Sverige (Forsmark & Johannesson 2020). Maskinell plantering står för en låg andel av utförandet av den årliga planteringen i Sverige, även om det har visats kunna ge lika bra biologiskt resultat som manuell plantering (Hallsby 2013). De planteringsmaskiner som idag används i praktiken bygger på kranspetsmonterade planteringsaggregat, och har för låg produktivitet för att vara konkurrenskraftiga i större omfattning (Ersson 2014).

Utveckling av mekaniserad plantering med maskiner som i samma moment markbereder och planterar, skulle kunna effektivisera skogsvården genom snabb återbeskogning och lägre kostnader. Det skulle även minska behovet av personal för manuell plantering som det sedan många år är brist på i Sverige.

1.1.1 Den ideala planteringspunkten

Tillgång av solljus, värme, koldioxid, vatten och mineraljord är essentiellt för plantors överlevnad och tillväxt (Hallsby 2013). En bra planterad planta bör sitta i en planteringspunkt som är minst 10 cm ifrån orörd humuskant och där marken omkring täcks av ren mineraljord. Planteringspunkten bör vara i nivå med eller högre än den omgivande marken då plantering i botten av gropar eller spår riskerar att en planta hamnar under vatten vid långa regnperioder och dör av syrebrist. Det är avgörande för plantan att ha lämpligt med vatten, och att planteringspunkt och planteringsdjup anpassas därefter. Även näringstillgången är en viktig faktor, vilket kan säkras genom att ge rötterna tillgång till inbäddad humus. Det optimala är att plantera djupt i en omvänd torva täckt av ren mineraljord. På finjordsrika marker finns dock risk för uppfrysning av plantorna. Det kan då även vara lämpligt att plantera i omvända torvor utan mineraljord eller i omarkberedd mark eftersom detta minskar uppfrysningsrisken. Omvänd torva med mineraljordstäckning bör då endast användas om plantan når ner i humus. Plantering i ren mineraljord bör undvikas, och om plantering ändå sker bör plantorna helst sättas i blekjord då rostjord är mer uppfrysningbenägen (Hallsby 2013).

1.2 Maskinell plantering

Planteringsmaskiner kan delas in i 3 olika metodbaserade kategorier (Hallonborg et al. 1997). Intermittent framryckande maskiner har normalt ett markberedande och planterande aggregat monterat i en kranspets. Detta är den typen av planteringsmaskin som idag till viss del används inom skogsbruket. Kontinuerligt framryckande maskiner markbereder och planterar samtidigt fortlöpande. Sedan finns även delmekaniserade lösningar där en maskin används för planttransport samt för mekanisk håltagning i marken för plantering.

Mekaniseringen av plantering har pågått till viss del ända sedan förra sekelskiftet (Malmberg 1990). Dessa första planteringsaggregat var utvecklade för plantering på tidigare ej beskogad mark och var konstruerade att direkt plantera plantor i en plogfåra skapad av en kontinuerligt plogande del som drogs av en traktor (Hallonborg et al. 1997). I Sverige intensifierades utvecklingen under 60-talet i samband med skogsbrukets allmänna mekanisering och till följd av bristande tillgång på arbetskraft (Hallonborg 1997; Hallonborg et al. 1997). Utvärderingar visade att kontinuerligt framryckande håltagande planteringsmaskiner var att föredra och blev den typen av maskin som den fortsatta utvecklingen fokuserades på (Hallonborg 1997). Baserat på utvecklingen av tidigare maskiner initierades 1981 Silva Nova projektet, vilket resulterade i en kapitalintensiv och tekniskt avancerad maskin med höga krav på organisering, trakt och plantor. Silva Nova bestod av en skotare med en midjemonterad markberedare med inåtriktade

harvtallrikar. Tiltorna kompakterades därmed av boggihjulen och planterades sedan av två planteringsarmar monterade längst bak på maskinen.

Under 90-talet lades dock Silva Nova projektet ner. Orsakerna var bland annat maskinens höga investeringskostnader, vilka inte kunde kompenseras med högre produktion i jämförelse med manuell plantering (Ersson 2010). Dessutom förlorade den konkurrenskraft i och med minskande traktstorlek sedan 70-talet. Plantornas överlevnad var generellt sämre än vid manuell plantering, och planteringsresultatet ansågs generellt vara för dåligt bland framför allt de privata skogsägarna. Då maskinen inte klarade av svårare terräng användes den främst på lättare trakter, vilket gav upphov till kritik då dessa annars skulle planterats av lokala ungdomar. Andra anledningar till att Silva Nova lades ner var höga administrations- och lönekostnader samt att arbetsmiljön för maskinförarna var dålig. I stället blev de intermittenta framryckande maskinerna mer ekonomiska och är den enda typen av maskiner som idag används (Ramantswana 2020).

På initiativ av Svenska Skogsplantor har nu ett projekt för att återuppliva Silva Nova-konceptet tagit fart i form av utvecklandet av en ny version av maskinen kallad Plantma X (Ramantswana 2020).

1.2.1 Plantma X

Plantma X är en kombinerat markberedande och planterande maskin utvecklad av Plantma AB, vilka är ett samarbete mellan Grangärde Konsult & Innovation, ATEK Arvidsson Teknik, Alftaprodukter, Midiflex och Grangärde Maskin (Plantma forestry u.å. c). Till stora delar är maskinen en vidareutveckling av Silva Nova. Utvecklingen av maskinen började 2018 och består i grunden av en Eco Log 574E skotare som basmaskin med ett MidiFlex markberedningsaggregat i midjan (Plantma forestry u.å. a). Harvtallrikarna är inåtriktade och maskinens bakre del kör därmed över markberedningen, vilket kompakterar marken och gör det möjligt att plantera direkt (Plantma forestry u.å. b). Markberedningen kan ställas in för plantering i tilla eller i spår. Då plantering sker i tilla sätts plantan i den kompakterade omvända torvan.



Figur 1. Plantma X planteringsmaskin (Foto: Sara Nilsson, Holmen Skog).
Figure 1. Plantma X planting machine (Photo: Sara Nilsson, Holmen Skog).

Maskinen kräver liksom den tidigare Silva Nova två operatörer, en i skotarhytten som styr körningen samt markberedningen, och en i bakre hytten som förser planteringsarmarna med plantor samt vid behov justerar armarnas inställningar utifrån markförhållanden och plantmaterial (Plantma forestry u.å. d). I bakre hytten finns utrymme för förvaring av 15 - 20 000 plantor beroende på plantstorlek. Plantorna sätts av operatören i ett band med koppar som transporterar ut plantorna till planteringsarmen där de faller ner genom en tratt vid plantering. Planteringen i sig styrs av ett styrsystem som planterar efter ett förinställt avstånd mellan plantorna. Respektive planteringsarm klarar att göra planteringsförsök var tredje sekund, och har under optimala förhållanden visats klara av att plantera 2800 plantor/timme (Plantma forestry u.å. a).

Likt Silva Nova är planteringsarmarnas spets försedd med en sensor (marksensor) som känner av markens hårdhet då spetsen träffar marken (Plantma forestry u.å. d). Om spetsen träffar olämplig mark, exempelvis en sten, en stubbe eller för mjukt underlag, går armen upp och styrsystemet startar ett nytt planteringsförsök. Om marken bedöms lämplig öppnas planteringsspetsen vilket skapar ett hål som plantan faller ner i. Därefter komprimerar tilltryckare jorden runt plantan, och armen går åter upp för att hämta en ny planta från bandet. Planteringen sker därmed kontinuerligt så länge armarna inte träffar för hårt underlag. För att

kompensera för avbrutet planteringsförsök beräknas avståndet till följande planteringspunkter om till att nå rätt antal plantor (Plantma forestry u.å. d).

Företaget Plantma AB arbetar på många områden för att utveckla maskinen. En viktig del för att förbättra planteringskvaliteten är att förhindra plantering i olämpliga planteringspunkter med för mycket humus eller grot, och en potentiell lösning på det är utveckling av bildanalysverktyg (Plantma forestry u.å. a).

1.2.2 Tidigare studier av Plantma X

Då maskinen är så pass ny finns få studier gjorda på maskinen. I en studie från 2021 utvärderades planteringsresultatet av maskinella planteringar med Plantma X med hänsyn till terrängegenskaperna blockkvot, stubbtäthet och humustjocklek för tall planterad i harvspår på moränmark (Tysklind 2021). Resultatet var att stubbtäthet och humustjocklek i kombination har negativ påverkan på planteringsresultatet, men att de enskilda egenskaperna inte har någon signifikant påverkan. Studien visade även att andelen underkända plantor var högre för maskinell plantering än manuell plantering. En trolig förklaring till resultatet var att maskinen inte kan se och välja ut lämpliga planteringspunkter. I en liknande studie av Dahlberg (2023) undersöktes planteringsresultatet efter plantering med Plantma X i både spår och omvänd torva. I denna studie var planteringsresultatet med Plantma X likvärdigt manuell plantering. Det visades inte heller någon signifikant skillnad i andel godkända plantor mellan plantering i spår och omvänd torva och påverkades inte av terrängegenskaperna blockkvot, stubbantal och humustjocklek. Dock är plantering i omvänd torva mer komplex än plantering i spår, och verktyg för lokalisering av planteringspunkter kommer därmed sannolikt vara en viktig del i utvecklingen av maskinen (Tysklind 2021; Manner & Ersson 2021).

Den andra studien som finns på Plantma X syftar till att utvärdera maskinens lämplighet för privatskogsbruket i Sverige (Ersson 2022). En av studiens slutsatser var att även om Plantma X, som utvecklats främst för storskogsbruket, i dagsläget planterar sämre än manuell plantering, är resultatet ändå tillräckligt bra för att ha potential att i framtiden kunna användas inom privatskogsbruket. Ersson bedömer att det finns stort möjlighet till utveckling vad gäller planteringskvaliteten, framför allt genom att ge maskinen ytterligare sensorer och automatisk identifiering av lämpliga planteringspunkter. Detta skulle göra maskinen mer lämplig för användning inom privatskogsbruket som kräver högre kvalitet än storskogsbruket (Ersson 2022).

1.3 AI och maskinseende

Artificiell intelligens (AI) kan beskrivas som datorsystem med syfte att efterlikna den mänskliga hjärnans förmågor (Nationalencyklopedin u.å.). Det är ett stort och

relativt nytt forskningsområde, och målen med AI ändras kontinuerligt. Likaså varierar vad som uppfattas vara AI i takt med utvecklingen.

Ett område inom AI är maskinseende vilket innefattar teknik där maskinen genom djupinlärning av digitala bilder kan prediktera innehållet i en bild och agera utifrån det (Skogforsk 2022). Djupinlärning är en samling av algoritmer för maskinlärning som används för att lösa problem kopplat till bilder, text och video. Olika typer av algoritmer passar olika typer av problem. En typ av algoritm kallas för *convolutional neural networks* (CNN) och används ofta för problem kopplade till bilder (Wang et al. 2021).

Maskinseende är en viktig del i framtida automatisering av skogsbruksåtgärder. Idag är sådan teknik inom skogsbruket generellt ännu inte särskilt utvecklat i praktiken, men exempel finns. I nuläget används djupinlärning för att till exempel utvärdera ytkvaliten på sågade trävaror, skogliga inventeringar, artidentifiering och för att uppskatta fukthalt i trä (Wang et al. 2021). Det har också utvecklats sätt att upptäcka skogsbränder genom datorseende (Wang et al. 2019).

Då dessa sätt att identifiera olika saker är kopplade till bilder kallas tekniken för bildigenkänning (Patil 2021).


1.3.1 Multiclass classification och andra tekniker

Inom bildigenkänning finns många olika tekniker. En sådan är *multiclass classification*, vilken bygger på att skapa en modell som placerar en bild inom en av flera möjliga klasser (Skogforsk 2022). Bilden kan endast bli tilldelad en av klasserna. Genom att använda en mängd bilder av de olika klasserna konstrueras en modell som kan prediktera vilken klass som nya bilder hör till (Bourel & Segura 2018). Det finns därför en avvägning mellan att anpassa modellen till bilderna som används för konstruktionen och modellens prestanda för att prediktera nya bilder.

En annan typ av teknik kallas för *semantic segmentation* som innebär att varje pixel klassas i olika kategorier utifrån vad pixeln representerar i bilden (Skogforsk 2022). Tekniken särskiljer dock inte olika objekt i bilden utan kategoriserar endast pixlarna (Jordan 2018).

1.3.2 Bildigenkänningsverktyg för Plantma X

En viktig utveckling av Plantma X är att få maskinen att undvika plantering i olämpliga planteringspunkter (Plantma Forestry u.å.). I ett utvecklingsprojekt av Plantma X tillsammans med Skogforsk, SCA, Sveaskog, arbetar Holmen med att utveckla ett bildigenkänningsverktyg i syfte att öka intelligensen i planteringsmaskinen och på så sätt förbättra valet av planteringspunkter (Sundström 2022). Verkyget består av en AI-modell som genom *multiclass classification* analyserar bilder av markberedningsspåret som tas av en kamera monterad på planteringsmaskinen (Figur 2).



Figur 2. Bildigenkänningsverktygets kamera monterad på Plantma X (Foto: Alice Kårehagen).
Figure 2. The image recognition tool's camera mounted on Plantma X (Photo: Alice Kårehagen).

Bilderna som analyseras har upplösningen 256 x 256 pixlar och motsvarar en cirka 25,6 x 25,6 cm yta på marken (Skogforsk 2022; Johansson pers. komm. 2022-09-07). Modellen har tränats med *Convolutional neural network* (CNN) med bilder indelade i tre klasser: *Mineraljord* – i huvudsak mineraljord, *Humus* – i huvudsak humus och *Ej planterbart* – i huvudsak ej planterbart (innefattande övrigt; omärkerbart, ris, vatten, sten med mera). Grundmodellerna har tränats på cirka 5000 manuellt klassade bilder. Modellen analyserar 8 bilder per sekund och ger för varje bild på markberedningsspåret en prediktion på sannolikheten för att bilden tillhör respektive klass. Dessa prediktioner kan användas i maskinen som ställbara tröskelvärden för godkänd planteringspunkt, och modellen signalerar utifrån dem planteringslämpligheten till maskinen. Då bilden av planteringspunkten inte bedöms vara godkänd av verktyget så upphör maskinen att plantera tills att det kommer en godkänd bild igen (Skogforsk 2022; Johansson pers. komm. 2022-09-07).

Modellen har vid utvärdering med valideringsdata visat klassa 92 % av bilderna korrekt (Johansson pers. komm. 2023-03-06). Skuggning från starkt solljus har identifierats vara en försvårande faktor för modellens prediktioner. I ett försök att reducera skuggbildningen och ge en jämn ljusbild har kraftfull arbetsbelysning monterats vid kamerorna, men det visade sig enbart fungera till viss del. Skuggning har även försvårat klassbedömningen på träningsbilderna, vilket även det försvårat prediktionen av bilderna för modellen (Johansson pers. komm. 2022-09-07).

1.4 Syfte

Det övergripande syftet med denna studie var att utvärdera hur stor andel av bildigenkänningsverktygets bedömningar som överensstämmer med en manuell plantörs fältbedömning av planteringspunkters lämplighet att planteras. Detta genom att besvara frågeställningarna:

- i. Kan olika tröskelvärden för bildigenkänningsverktygets prediktering av sannolikheten för att en planteringspunkt består av mineraljord, humus och ej planterbart förändra överensstämmelsen med fältbedömning?
- ii. Påverkar olika ljusförhållanden som sol, halvskugga och skugga bildigenkänningsverktygets prediktioner?
- iii. Finns det skillnad i hur stor andel av bildigenkänningsverktygets bedömningar som överensstämmer med fältbedömning för planteringspunkter i markberedningens spår respektive tilta?

Hypoteserna är följande:

- i. Genom att justera tröskelvärdena kan överensstämmelsen mot fältbedömningen förbättras.
- ii. Solljus och medförande skuggbildning kommer att påverka bildigenkänningsverktygets bedömning negativt.
- iii. Överensstämmelsen är högre i det mer homogena spåret än i tiltan.

1.5 Avgränsningar

Studien avgränsas till ett relativt snävt spektrum av markfuktighetsförhållanden och jordart, innefattande tre friska trakter med sandig-moig morän och en fuktig trakt med finkorniga sediment. Avgränsning görs även till att utföras under hösten med viss en växtlighet och lägre stående sol i förhållande till den tidigare delen av planteringssäsongen under vår och sommar.

Studien behandlar endast markberedning med harv som direkt kompakteras genom överkörning av maskin.

2. Material och Metod

Studien genomfördes oberoende av planteringsmaskinen på det sätt att en separat kamera användes för insamling av bilder på planteringspunkter som sedan analyserades i bildigenkänningsverktyget i efterhand.

2.1 Studieområde

Plantma X har under hösten 2022 körts på Holmens marker omkring Bredbyn i Västernorrlands län (Tabell 1). Fältinventeringen genomfördes under september och oktober 2022 på fyra trakter som markberetts och planterats med Plantma X i september 2022.

Tabell 1. Traktegenskaper för trakter använda vid datainsamling av bilder. Grundförhållande, ytstruktur, och lutning (GYL), höjd över havet och vegetationstyp för hela trakten enligt Holmens beståndsregister. Jordart och markfuktighet enligt fältbedömningar inom försöksyta *Table 1. Site properties for sites used for data collection of images. Base condition, surface structure, and slope ("GYL"), height above sea level and vegetation type for the entire area according to Holmen's register. Soil type and soil moisture according to field assessments within the experimental area*

	Vålandsmyr	Holmsjöväg	Lappmyran	Storfors
GYL	231	331	231	222
Höjd över havet (m)	324	295	292	234
Jordart	Sandig-moig morän	Sandig-moig morän	Sandig-moig morän	Finkorniga sediment
Markfuktighet	Frisk	Frisk	Frisk	Fuktig
Vegetationstyp	Blåbärstyp	Blåbärstyp	Blåbärstyp	Blåbärstyp
Antal provytor då mulet väder	59	82	66	96
- Därav i spår	29	45	29	50
- Därav i tilta	30	37	37	46
Antal provytor då soligt väder	40	41	4	32
Antal provytor totalt	99	123	70	128

2.2 Datainsamling

Datainsamlingen bestod av att ta bilder motsvarande de som tas av bildigenkänningsverktygets kamera på Plantma X-maskinen, samt som referensmätning i fält manuellt bedöma planteringspunkterna enligt Holmens uppföljningsinstruktion för manuell plantering.

2.2.1 Utläggning av provytor

För att förhållandena under datainsamlingen skulle motsvara dem då verktyget används på maskinen inventerades trakter där Plantma X nyligen använts. Detta för att undvika att markberedningen hunnit påverkas allt för mycket av exempelvis regn. Plantma X har harvtallrikarna riktade inåt och komprimerar därmed harvspåret när det körs över, vilket skiljer den från konventionella markberedare med harv och varför inventeringen inte utfördes på sådana konventionellt markberedda trakter.

Provytorna lades ut inom traktområden där Plantma X planteringskvalitet studeras i ett annat försök och inställningar för spår respektive tilta var därför uppmärkt, vilket nyttjades i denna studie. En startpunkt togs slumpmässigt fram, och följande provytor lades ut med 2 meters intervall.

Då inventering genomfördes efter körning med Plantma X innebar det att plantorna redan var satta, vilka inte var önskvärda att ha med i bilden. Då en planta hamnade inom provytan flyttades därför provytan framåt 3 dm.

Varje provyta utgjordes av en 25,6 x 25,6 cm yta i markberedningsspåret, vilket motsvarar en potentiell planteringspunkt där 10 cm mineraljord från plantan till humuskant är önskvärdt. En provyteram användes för att markera provytans område i fält och i bilden. Provyteramen hade måtten 32 x 32 cm och markeringar för 25,6 x 25,6 cm. Detta eftersom provytan i bilden inte ska bli för liten då bilden tas lodrätt och marken inte är helt plan.

Där maskinen markberett med inställningar för plantering i tilta lades provytan ut i tiltan, och där maskinen markberett för plantering i spår lades provytan ut i spåret. Antalet insamlade bilder i tilta respektive i spår eftersträvades vara så jämnt som möjligt. Bilder togs även då provytan hamnade på omarkerat eller ej planterbart område.

2.2.2 Bildinsamling

För insamlingen av bilder krävdes en kamera med möjlighet att fotografera i upplösningen 256 x 256 pixlar eller i en multipel av det, för att motsvara de bilder som kameran på Plantma X tar. Kameran som användes i denna studie var en *GoPro Hero10*.

Bilderna togs lodrätt med hjälp av ett kamerastativ med inbyggt vattenpass på cirka 65 cm höjd för att uppnå 1024x1024 pixlar (en multipel av 256x256) inom

provyteramen (Figur 3). Höjden mellan kamera och provyta mättes upp med måttband. Ramen lades ut så att den i bilden blev placerad vinkelrätt för att underlätta den senare bildbeskärningen och bildbearbetningen. Bilderna som togs inkluderade provyteramen samt området omkring för att också ge en bra referens på det området i förhållande till ramen.



Figur 3. Uppställning av utrustning för insamling av bilder på provytorna (Foto: Alice Kårehagen).
Figure 3. Setup of equipment for collecting photos of the sample spots (Photo: Alice Kårehagen).

2.2.3 Manuell fältbedömning av planteringspunkt

Provytan bedömdes in i planteringspunktsklasser enligt Holmen Skogs uppföljningsinstruktion för manuell plantering (Tabell 2) som kombinerades med kompletterande bedömningar. Bedömningen av planteringspunkten gjordes utifrån att en planta i teorin skulle varit planterad i provytans centrum. Denna instruktion har olika krav för *Bra* planteringspunkt beroende på markfuktighetsklass och jordart.

Tabell 2. Beskrivning av planteringspunktsklasser enligt Holmens uppföljningsinstruktion för manuell plantering

Table 2. Description of planting spot classes according to Holmen's instructions for follow-up on manual planting

Optimal	Bra	Övrig
<ul style="list-style-type: none"> – Mineraljord på omvänd torva där plantan sitter minst 10 cm från humuskant. Den omvända torvan ska ha kontakt med underliggande mark. 	<ul style="list-style-type: none"> – Blekjordsfläck på torr och frisk mark där plantan sitter minst 10 cm från humuskant. – Omvänd torva på fuktig mark, finjordsrik mark och på torvmark med för lite eller ingen mineraljord. Den omvända torvan ska ha kontakt med underliggande mark. På region Nord och Mitt kan denna planteringspunkt användas på frisk mark mer än 100 km från kusten eller om plantorna har snytbaggesskydd. 	<ul style="list-style-type: none"> – Omvänd torva som inte uppfyller ovanstående krav. – Rostjordsfläck (på torr och frisk mark). – Humusfläck. – Mineraljordsfläckar på fuktig och finkornsrik mark. – Oberedd mark. – Omvända torvor med dålig markkontakt.

Bedömningen kompletterades med ytterligare manuell bedömning i fält av huruvida planteringspunkten var planterbar eller ej, samt om den var omarkberedd. Förutsättningar som bedömdes vara ej planterbara var då mer än ca 25 % av provytan utgjordes av hinder som till exempel större stenar, rötter, ris, stammar. En provyta kan vara bedömd som både omarkberedd och ej planterbar.

2.2.4 Traktförhållanden

För att kunna utvärdera om olika traktförhållanden påverkar hur väl bildigenkänningsverktyget fungerar och möjlighet till förbättring av val av planteringspunkt, antecknades de för traktområdet rådande förhållandena. De faktorer som noterades var markfuktighetsklass enligt klasserna *Torr*, *Frisk*, *Fuktig*, *Blöt* och väderförhållanden i klasserna *Sol* och *Mulet*. Det förekom både regn och uppehåll under studien. Vid soliga väderförhållanden samlades totalt 3 bilder in per provyta; en utan skuggning, en där halva provytan skuggades och en där hela provytan skuggades. Provytorna skuggades med hjälp av en skärm. Detta för att kunna undersöka hur olika grader av skuggbildning påverkar bildigenkänningsverktygets resultat.

Förhållandena noterades för hela trakten vid ankomst. Eventuella ändringar under inventeringens gång noterades också.

2.2.5 Bearbetning och analys av bilder

I och med att de insamlade bilderna även innehåller referensområdet utanför provytan behövde de bearbetas till att endast innehålla provytan innan de kunde analyseras av bildigenkänningsverktyget. Detta gjordes med hjälp av ett program som Skogforsk bistod med och kördes med programvaran *GNU Octave*. Programmet beskär ut provytan motsvarande 1024 x 1024 pixlar ur bilden, ändrar storleken till 256 x 256 pixlar och sparar ner den som en ny bild (Figur 4). Varje bildbeskärning förhandsgranskades och godkändes manuellt.



Figur 4. Exempel på originalbild (till vänster) och bild efter att provytan, motsvarande området innanför ramens vita markeringar, blivit utskuren (till höger) (Foto: Alice Kårehagen).
Figure 4. Example of original image (on the left) and image after the sample spot, corresponding to the area within the white markings on the frame, has been cut out (on the right) (Photo: Alice Kårehagen).

De beskurna bilderna bedömdes sedan av bildigenkänningsverktyget. För detta bistod Skogforsk med hjälp. Utfallet av bildigenkänningsverktygets analys gav för respektive bild en prediktion på sannolikheten för att bilden tillhör respektive klass av de tre klasserna: Mineraljord, Humus och Ej planterbart. Sannolikheterna för dessa tre klasser summeras till 100 %. På grund av hur bildigenkänningsverktyget avrundar, kan dock sannolikheterna ibland summeras till endast 98 eller 99 %. Möjligtvis kan sannolikheterna även summeras till 101 eller 102 %, men ingen sådan observation har gjorts i denna studie. Notera att sannolikheten inte motsvarar andelen av respektive klass i bilden.

2.3 Analys och statistik

Insamlat data sammanställdes i ett Excel-dokument, och delades upp i två dataset. Ett set med bildtripleterna av provytor insamlade under soliga väderförhållanden, och ett set med bilder av provytor insamlade under mulna väderförhållanden (Tabell 1).

I första steget valdes två olika manuella fältbedömningar att jämföra bildigenkänningsverktygets bedömning mot. Den ena härnäst kallade ”Holmen-bedömningen” bestående av den manuella fältbedömningen enligt Holmen Skogs uppföljningsinstruktion för manuell plantering. I denna bedöms *Optimala* och *Bra* provytor som godkända, och *Övriga* provytor som underkända. Den andra fältbedömningen var den härnäst kallade ”Planterbart-bedömningen”. Denna innebär att provytor i fält manuellt bedömda som ej planterbara eller omärkbara är underkända, och övriga godkända

För att utvärdera respektive prediktionsklass lämplighet att användas som tröskelvärde i bildigenkänningsverktyget skapades så kallade ROC (*Receiver Operator Characteristic*) – kurvor (Robin et al. 2011; Nahm 2022). En ROC-kurva visar prestandan för en klassificeringsmodell vid alla möjliga klassificeringströskelvärden. Klassificeringsmodeller skapades genom att ta fram logistiska regressionsmodeller med respektive prediktionsklass som klassificerare av de två olika manuella fältbedömningarna. Då ett visst klassificeringströskelvärde sätts för en klassificeringsmodell innebär det att de högre värdena klassas som godkända provytor och lägre värden som underkända. En ROC-kurva visar *True Positive Percentage* (TPP) som en funktion av *False Positive Percentage* (FPP), och kan därmed visa utfallet för alla möjliga klassificeringströskelvärden för klassificeringsmodellen. TPP beräknas som andelen av provytor som enligt fältbedömning är godkända (TP + FN) som också klassas som godkända av den klassificeringsmodellen (TP) vid det bestämda klassificeringströskelvärdet (Tabell 3 och Ekvation 1). FPP beräknas på samma sätt men med skillnaden att det i stället visar andelen av provytor som enligt fältbedömning är underkända (FP + TN) men som klassas som godkända (FP) vid det bestämda klassificeringströskelvärdet (Tabell 3 och Ekvation 2).

Tabell 3. Parametrar för konstruktion av ROC (Receiver Operator Characteristic) - kurva.
Table 3. Parameters for construction of ROC (Receiver Operator Characteristic) - curve.

		Fältbedömning	
		Godkänd	Underkänd
Klassificeringsmodell	Godkänd	Sanna positiva (TP)	Falska positiva (FP)
	Underkänd	Falska negativa (FN)	Sanna negativa (TN)

Ekvation 1. Beräkning av True Positive Percentage (TPP).

$$TPP = \frac{TP}{TP + FN} \times 100$$

Ekvation 2. Beräkning av False Positive Percentage (FPP).

$$FPP = \frac{FP}{FP + TN} \times 100$$

Då TPP är 100% innebär det att inga godkända provytor har klassats som underkända, och då FPP är 0% innebär det att inga underkända provytor har klassats som godkända. En perfekt klassificerare ger därmed en ROC-kurva som går från punkt (0, 0) till (0, 100) och från (0, 100) till (100, 100), och innebär att alla provytor klassas rätt vid alla möjliga klassificeringströskelvärden. Av dessa kurvor beräknades även AUC (*Area Under the Curve*) som är hur stor andel av den sammanlagda arean ovanför och under ROC-kurvan, som återfinns under ROC-kurvan. AUC är ett värde på separerbarheten, det vill säga hur effektivt klassificeringsmodellen skiljer på godkända och ej godkända provytor enligt fältbedömningen. Desto högre AUC, desto bättre är modellen på detta. Det maximala och optimala värdet på AUC är 100 %. Utifrån samtliga värden på ROC-kurvorna beräknades sedan vilken punkt som gav den maximala differensen av TPP och FPP. Vid detta värde är antalet felklassade provytor som lägst, och motsvarar det för modellen optimala klassificeringströskelvärdet. Korresponderande tröskelvärde för bildigenkänningsverktygets prediktion kunde därefter läsas av från klassificeringsmodellerna. Dessa analyser utfördes i programmet *R studio* med paketet *pROC* (Robin et al. 2011) för data från mulna väderförhållanden.

I nästa steg analyserades om prediktionsklassernas lämplighet som tröskelvärden påverkas av ljusförhållanden. Detta gjordes med data från soliga väderförhållanden och genom att jämföra bildigenkänningsverktygets prediktioner i sol, halvskugga och skugga mot varandra för respektive prediktionsklass.

Differensen av prediktionerna i de tre ljusförhållandena beräknades för respektive klass och provyta; prediktionen i sol subtraherades med prediktionen i halvskugga, prediktionen i sol subtraherades med prediktionen i skugga och prediktionen i halvskugga subtraherades med prediktionen i skugga. För respektive provyta erhöles därmed ett värde per differens och klass. För respektive differens och klass skapades histogram för att avgöra om de var normalfördelade eller ej. För ytterligare säkerhet i om differenserna var normalfördelade utfördes även Shapiro-tester för samtliga differenser och klasser. Sedan beräknades en median, medelvärde och standardavvikelse för alla provytor för respektive differens och klass. Wilcoxon signed-rank test utfördes för respektive differens och klass för att upptäcka potentiella signifikanta skillnader mellan prediktionerna i de tre ljusförhållandena. En signifikansnivå på $\alpha = 0,05$ användes för dessa tester, vilken anpassades till antalet tester genom Bonferroni-korrigerig. Även dessa tester utfördes i programmet *R Studio*.

I nästa steg beräknades överensstämningen mellan bildigenkänningsverktygets bedömning och de manuella fältbedömningarna i programmet *Excel* för olika tröskelvärden på de tre prediktionsklasserna Mineraljord, Humus och Ej planterbart. Detta beräknades genom att dividera antalet provytor som med ett bestämt tröskelvärde gav samma bedömning (godkänd eller underkänd) som Holmen-bedömningen respektive Planterbart-bedömningen med det totala antalet provytor i datasetet. De tröskelvärdena som testades ställdes in manuellt. Överensstämmelse mellan verktygets prediktioner under mulna väderförhållanden och manuella fältbedömningar beräknades för tröskelvärdena Mineraljord 0-100 % i intervall om 10 %, och Ej planterbart 0, 5, 10, 20, 30, 40, 70 och 100 (%). På grund av tidsbrist användes ett bredare intervall av tröskelvärden för Ej planterbart mellan 40 – 100 %, vilket inte bedömdes påverka resultatet i större utsträckning eftersom högst överensstämmelser gavs då tröskelvärdet var under 40 %. Funktionerna som användes för beräkningen av överensstämningen konstruerades så att för klasserna Humus och Ej planterbart så godkändes provytan om prediktionerna var lägre än det satta tröskelvärdet och underkändes om det var högre. För klassen Mineraljord konstruerades funktionen så att provytan i stället godkändes om prediktionen var högre än det satta tröskelvärdet, och underkända om det var lägre.

För att kontrollera bildigenkänningsverktygets robusthet beräknades detta även efter uppdelning utifrån läge i markberedningen (spår respektive tilla), trakt, samt både läge och trakt. Till sist testades de optimala tröskelvärden för data från mulna väderförhållanden på data från soliga väderförhållanden. Detta för att få en validering av de optimala tröskelvärdena samt att jämföra överensstämningen vid olika ljusförhållanden och få ett mått på ljusförhållandets praktiska påverkan på bildigenkänningsverktyget.


3. Resultat

3.1 Utvärdering av prediktionsklasser

3.1.1 Prediktion vid mulna väderförhållanden

ROC-kurvor (Figur 5) skapade utifrån logistiska regressionsmodeller för respektive prediktionsklass visade att ingen av klasserna enskilt fungerar optimalt som klassificerare för att avgöra om provytorna är godkända eller ej enligt Holmenbedömningen för provytor under mulna väderförhållanden.

ROC-kurvorna visar att modellen baserad på klassen Mineraljord presterar bäst som klassificerare (AUC 89,0 %), att modellen baserad på klassen Ej planterbart presterar nästan lika väl (AUC 85,5 %), och att modellen baserad på klassen Humus presterar sämst (AUC 68,7 %). Den högsta differensen av *True Positive Percentage* (TPP) och *False Positive Percentage* (FPP) ges av klassen Mineraljord som klassificerare.



Figur 5. ROC (Receiver Operator Characteristic) – kurvor och för dessa korresponderande värden på AUC (Area Under the Curve) för logistiska regressionsmodeller (klassificeringsmodeller) (Figur 6) med respektive prediktionsklass för bildigenkänningsverktyget (Mineraljord, Humus och Ej planterbart) som klassificerare för Holmen-bedömningen. På y-axeln visas andel provtytor som enligt fältbedömning är godkända och som klassas som godkända av klassificeringsmodellen (TPP). På x-axeln visas andel provtytor som enligt fältbedömning är underkända men som klassas som godkända av klassificeringsmodellen (FPP). En optimal ROC-kurva går från punkt (0, 0) till (0, 100) och från (0, 100) till (100, 100). Den 45° diagonala linjen motsvarar en ROC-kurva då klassningen sker slumpmässigt.

Figure 5. ROC (Receiver Operator Characteristic) curves and corresponding AUC (Area Under the Curve) values of logistic regression models (classification models)(Figure 4) with the respective prediction class for the image recognition tool (Mineral soil, Humus and Not plantable) as classifiers for the Holmen assessment. The y-axis shows the proportion of planting spots which are approved according to the field assessment and are classified as approved by the classification model (TPP). The x-axis shows the proportion of planting spots that are disapproved according to the field assessment but are classified as approved by the classification model (FPP). An optimal ROC curve goes from point (0, 0) to (0, 100) and from (0, 100) to (100, 100). The 45° diagonal line corresponds to an ROC curve where the classification is random.

De logistiska regressionsmodellerna gav att det bästa korresponderande tröskelvärdet för prediktionsklassen Mineraljord är ca 40 %, för prediktionsklassen Humus ca 35 %, och för prediktionsklassen Ej planterbart ca 0 % (Figur 6). Det vill

säga, det värde som enligt ROC-kurvorna ges vid den högsta differensen av TPP och FPP.

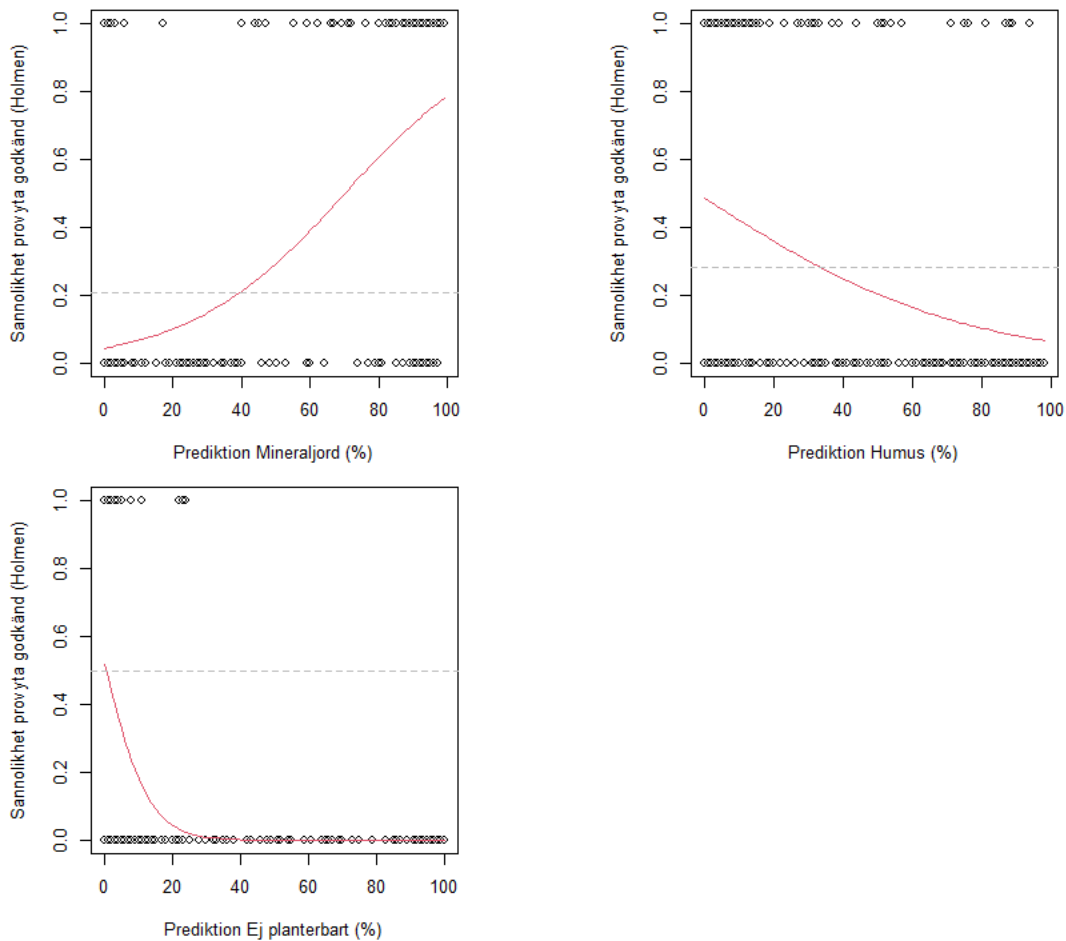


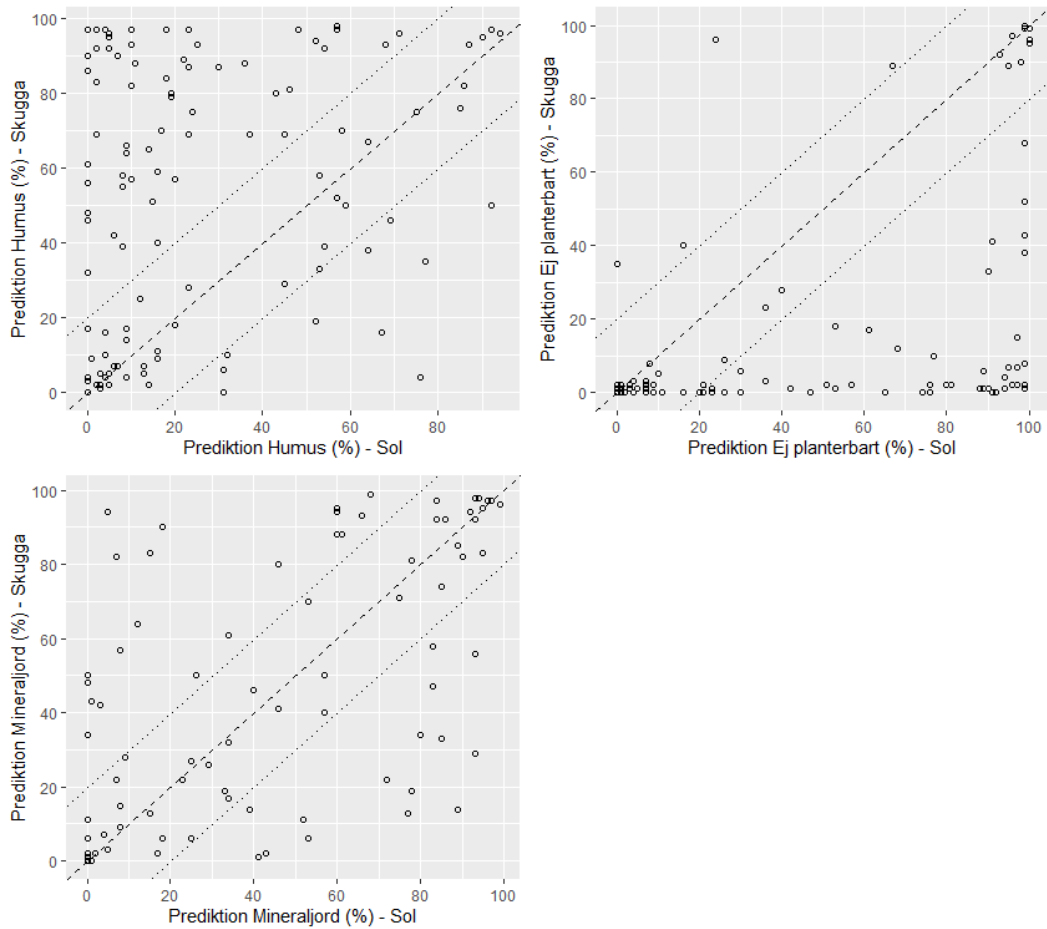
Figure 6. Logistiska regressionsmodeller (klassificeringsmodeller) med de tre prediktionsklasserna Mineraljord (ö.v.), Humus (ö.h.) och Ej planterbart (n.v.) som klassificerare av Holmen-bedömning. Modellerna visar sannolikheten att en provyta bedöms som godkänd baserat på bildigenkänningsverktygets prediktion av respektive klass. Den vågräta grå streckade linjen visar optimalt tröskelvärde för regressionsmodellen och motsvarar det maximala värdet för differensen av True Positive Percentage (TPP) och False Positive Percentage (FPP) i Receiver Operator Characteristic (ROC) - kurvorna. Skärningspunkten är även det optimala tröskelvärdet för prediktionsklassen som enskild klassificerare i bildigenkänningsverktyget (x-axeln).

Figure 6. Logistic regression models (classification models) with the three prediction classes Mineral soil (left), Humus (right) and Not plantable (right) as classifiers of Holmen's assessment. The models show the probability of a sample being assessed as approved based on the image recognition tool's prediction of each class. The grey horizontal dashed line shows the optimal threshold value for the regression model and corresponds to the maximum value of the difference of True Positive Percentage (TPP) and False Positive Percentage (FPP) of the Receiver Operator Characteristic (ROC) curves. The intersection point is also the optimal threshold value for the prediction class as a single classifier in the image recognition tool (x-axis).

Enligt denna analys bör prediktionerna för sannolikheten av klasserna Mineraljord och Ej planterbart vara lämpligast att använda som tröskelvärden i bildigenkänningsverktyget i skugga för att fatta ett så bra beslut som möjligt om att plantera eller ej. Prediktionen för sannolikheten av klassen Humus bör därmed vara minst lämpligt som tröskelvärde. Samma analys för Planterbart-bedömningen visade att ingen av prediktionsklasserna fungerade som klassificerare. Med anledning av detta redovisas endast resultat för Mineraljord och Ej planterbart som tröskelvärden samt för Holmen-bedömningen.

3.1.2 Jämförelse av prediktioner i sol och skugga

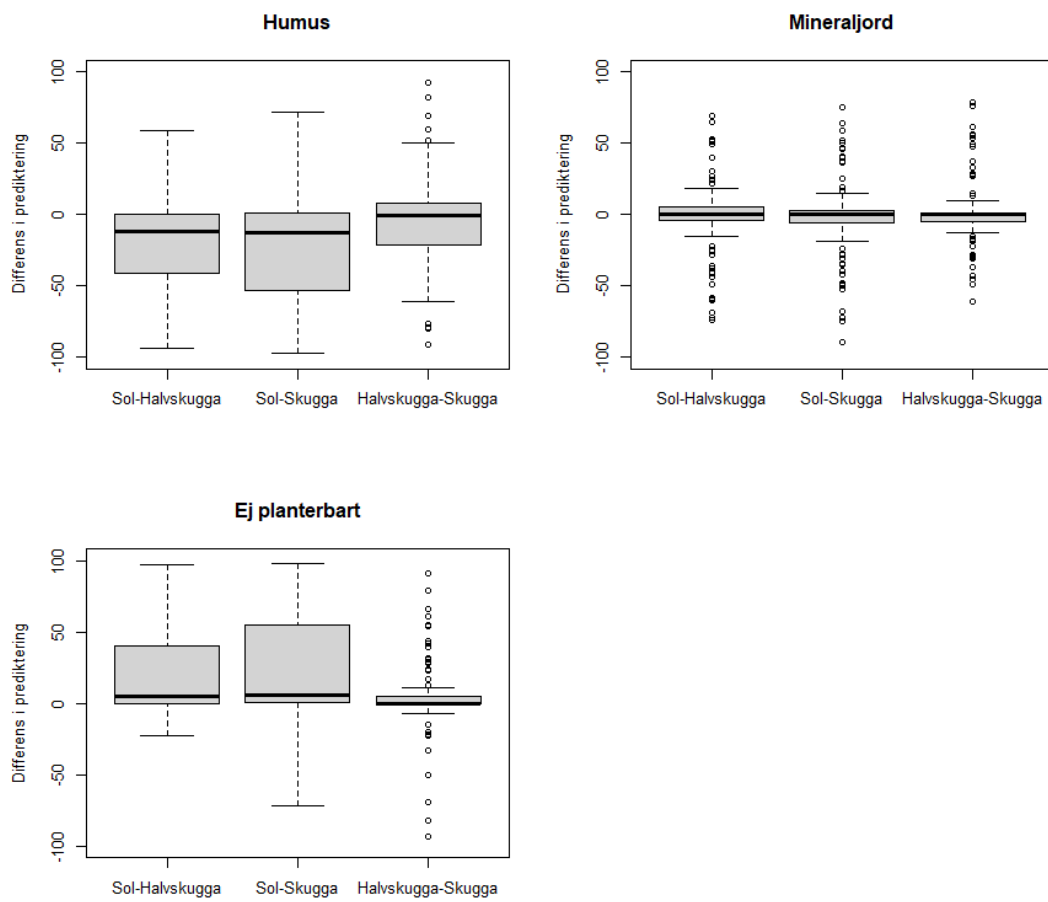
Det finns betydande skillnader i bildigenkänningsverktygets prediktioner i sol respektive skugga för alla tre prediktionsklasser (Figur 7). Av de tre klasserna har prediktionerna för klassen Mineraljord lägst variation mellan ljusförhållandena sol och skugga. Då prediktionen i sol är kring 0 % sannolikhet för Ej planterbart är även prediktionen i skugga kring 0 % (Figur 7 ö.h.). För klassen Ej planterbart är prediktioner kring 0 % vanligast i skugga, medan prediktioner i sol har stor spridning.



Figur 7. Prediktion i sol (x-axel) plottat mot prediktion i skugga (y-axel) för klasserna Humus (ö.v.), Ej planterbart (ö.h.) och Mineraljord (n.v.). Streckad linje visar fullkomlig överensstämmelse av prediktioner i sol och skugga. Prickade linjer visar +/- 20 %-enheter av streckad linje.
Figure 7. Prediction in sun (x-axis) plotted against prediction in shade (y-axis) for the classes Humus (t.l.), Not plantable (t.r.) and Mineral soil (b.l.). Dashed line shows perfect agreement of predictions in sun and shade. Dotted lines show +/- 20 % units of dashed line.

Medelvärde och median av differenserna av ljusförhållandena är lägre för klassen Mineraljord än för klasserna Humus och Ej planterbart (Figur 8 och Tabell 4). Dock har alla tre klassernas prediktioner hög standardavvikelse.

För klasserna Mineraljord och Humus ges lägre prediktering av sannolikheten i sol än i halvskugga och skugga (Tabell 4). För klassen Ej planterbart ges tvärtom högre prediktering i sol än halvskugga och skugga. För klasserna Mineraljord och Ej planterbart ges högre prediktering i halvskugga än i skugga, medan högre prediktering ges i skugga än i halvskugga för klassen Humus.



Figur 8. Låddiagram av differenserna i prediktering för de olika ljusförhållandena för respektive predikteringsklass, Humus (ö.v.), Mineraljord (ö.h.) och Ej planterbart (n.v).
Figure 8. Box plot of the differences in prediction for the different light conditions for each prediction class, Humus (t.l.), Mineral soil (t.h.) and Not plantable (b.l.).

Tabell 4. Median, medelvärde, standardavvikelse och p-värde av Wilcoxon signed-rank test för differenserna i bildigenkänningverkygets prediktering för respektive klass i de olika ljusförhållandena. Signifikansnivån är $\alpha = 0,0167$ (efter Bonferroni-korrektion). * = signifikant skillnad

*Table 4. Median, mean, standard deviation and p-value of the Wilcoxon signed-rank test for the differences in the image recognition tool's prediction for each class in the different light conditions. The significance level is $\alpha = 0.0167$ (after Bonferroni correction). * = significant difference*

Klass	Differens	Median	Medelvärde	Standardavv.	p-värde
Humus	Sol-Halvskugga	-12.0	-19.8	32.5	<0,01*
Humus	Sol-Skugga	-13.0	-25.0	37.5	<0,01*
Humus	Halvskugga-Skugga	-1.0	-5.2	31.7	0,077
Mineraljord	Sol-Halvskugga	0.0	-2.4	25.8	0,609
Mineraljord	Sol-Skugga	0.0	-1.3	27.0	0,618
Mineraljord	Halvskugga-Skugga	0.0	1.0	22.1	0,629
Ej planterbart	Sol-Halvskugga	5.0	22.4	29.5	<0,01*
Ej planterbart	Sol-Skugga	6.0	26.4	36.5	<0,01*
Ej planterbart	Halvskugga-Skugga	0.0	4.0	25.2	<0,01*

Utifrån histogram samt Shapiro-tester kunde differenserna av prediktionerna i de olika ljusförhållandena inte antas vara normalfördelade. För att vidare undersöka skillnader i prediktionerna genomfördes därför Wilcoxon signed-rank test. Tre test per prediktionsklass utfördes för att jämföra alla ljusförhållanden mot varandra. Signifikansnivån korrigerades utifrån antal test till $\alpha = 0,0167$. Resultatet visade för klassen Humus signifikant skillnad mellan modellens prediktioner i sol och halvskugga, samt sol och skugga (Tabell 4). Skillnaden på prediktionerna i halvskugga och skugga var dock inte signifikant. För klassen Ej planterbart visades signifikant skillnad för alla tre prediktionerna. För klassen Mineraljord visades ingen signifikant skillnad för någon av prediktionerna.

Klassen Mineraljord är alltså den prediktionsklassen som påverkas minst av rådande ljusförhållanden och bör därför vara den mest lämpliga att använda som tröskelvärde även vid soliga väderförhållanden. I fortsatta analyser användes endast klasserna Mineraljord och Ej planterbart som tröskelvärden.

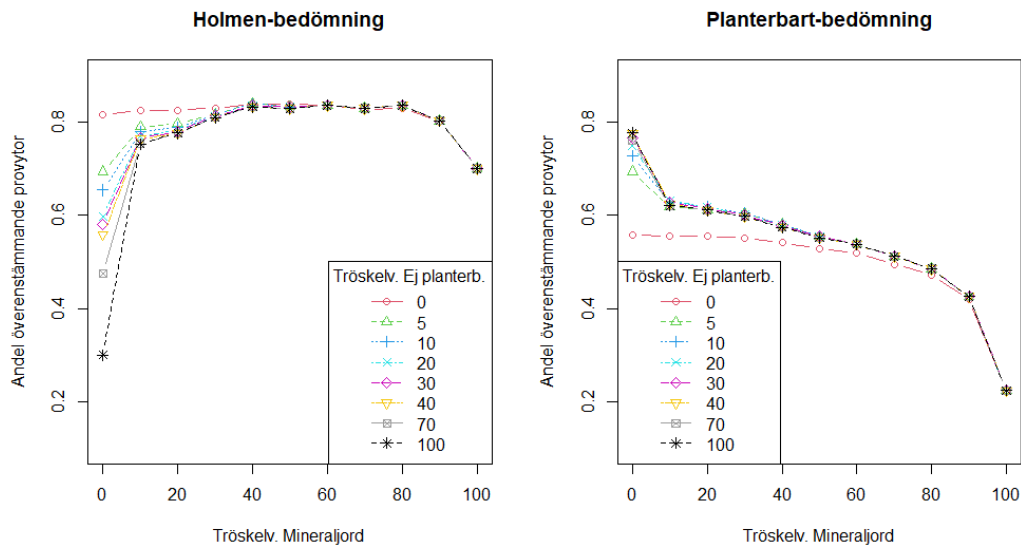
3.2 Tröskelvärden för *Mineraljord* och *Ej planterbart* för bästa överensstämmelse med fältbedömningar

3.2.1 Optimala tröskelvärden för alla trakter tillsammans i mulet väder

Av samtliga provvytor insamlade under mulna väderförhållanden bedömdes i fält 33 % vara godkända (*Bra* eller *Optimal*) och 67 % underkända (*Övrig*) enligt Holmens instruktioner (Bilaga 1). Vid Planterbart-bedömningen bedömdes 78 % som godkända och 22 % som underkända.

Högsta överensstämmelse med Holmenbedömningen blev 83,8 %. Den erhöles då tröskelvärdet för *Ej planterbart* var 0-10% och för *Mineraljord* var 40 %. Samma överensstämmelse kunde uppnås även med *Ej planterbart* 0 % och *Mineraljord* 50 % (Figur 9 t.v.). Då båda tröskelvärdena sätts att godkänna alla prediktioner ges 30,0 % överensstämmelse.

Högsta överensstämmelsen med *Planterbart*-bedömningen, 77,6 %, ges då tröskelvärdet för *Ej planterbart* och *Mineraljord* sätts till 100 % respektive 0 %, det vill säga att alla prediktioner godkänns för plantering, eller då *Ej planterbart* i stället sätts till 30-40 % (Figur 9 t.h.).



Figur 9. Andel överensstämmande provvytor med Holmen-bedömningen (t.v.) respektive enligt *Planterbart*-bedömningen (t.h.) för olika tröskelvärde-inställningar för klasserna *Mineraljord* och *Ej planterbart*.

Figure 9. Proportion of samples in agreement to the Holmen assessment (left) and the *Plantable* assessment (right) for different threshold value settings for the classes *Mineral soil* and *Not plantable*.

3.2.2 Optimala tröskelvärden per trakt

Då tröskelvärdena för klasserna Mineraljord och Ej planterbart optimeras för respektive trakt uppnås högre överensstämmelse per trakt än för alla trakter tillsammans för trakterna Holmsjöväg, Lappmyran och Vålandsmyr. För trakten Storfors nås i stället lägre överensstämmelse (Tabell 5). Med tröskelvärdeninställningarna Mineraljord 40-50 % och Ej planterbart 0-5 %, kan högsta överensstämmelse för respektive trakt nås för samtliga trakter.

Tabell 5. Högsta överensstämmelse med Holmen-bedömningen per trakt och motsvarande tröskelvärden för att uppnå dessa. Prediktioner godkänns för plantering om dessa är \geq tröskelvärdet för Mineraljord och \leq tröskelvärdena för Ej planterbart. För vissa trakter ges samma överensstämmelse vid flera olika kombinationer av tröskelvärden.

Table 5. Highest agreement with the Holmen assessment per site and the corresponding threshold values to achieve these. Predictions are approved for planting if these are \geq the threshold for Mineral Soil and \leq the threshold for Not Plantable. For some site the same agreement is given at various combinations of thresholds

Trakt	Högsta överensstämmelse (%)	Tröskelvärden för högsta överensstämmelse (%)	
		Mineraljord	Ej planterbart
Holmsjöväg	89,0	50-60	0
		70	0-100
Lappmyran	97,0	40	5-10
Storfors	74,0	40	0
Vålandsmyr	88,1	30-60	0
		80	0-100

Det innebär att alla fyra trakter uppnår högsta överensstämmelse med något av de tröskelvärden som också gav högst överensstämmelse för alla trakter tillsammans (Tabell 6). Trakterna skiljer sig dock åt i vilket av de fyra optimala tröskelvärdeskombinationerna (avsnitt 3.2.1) som ger högst överensstämmelse.


Tabell 6. Andel överensstämmelse med Holmen-bedömningen per trakt vid användning av optimala tröskelvärden (se 3.2) på klasserna Mineraljord och Ej planterbart för alla trakter tillsammans. Till exempel "M40E0" motsvarar tröskelvärdena Mineraljord 40 % och Ej planterbart 0 %. Högsta värden fetstilta. Prediktioner godkänns för plantering om dessa är \geq tröskelvärdet för Mineraljord och \leq tröskelvärdena för Ej planterbart.

Table 6. Percentage of compliance with the Holmen assessment per site when using optimal threshold values (see 3.2) for the classes Mineral soil and Not plantable for all tracts together. For example, "M40E0" corresponds to the threshold values Mineral soil 40 % and Not plantable 0 %. Highest values in bold. Predictions are approved for planting if these are \geq the threshold for Mineral Soil and \leq the threshold for Not Plantable.

Trakt	Överensstämmelse vid optimala tröskelvärden (%)			
	M40E0	M40E5	M40E10	M50E0
Holmsjöväg	87,8	86,6	86,6	89,0
Lappmyran	89,4	97,0	97,0	89,4
Storfors	74,0	72,9	72,9	72,9
Vålandsmyr	88,1	83,1	83,1	88,1

3.2.3 Prediktionsklassen Ej planterbart - Överensstämming med fältbedömning

Av totalt 98 provytor som i fält bedömts som ej planterbara, omärkberedda eller både och, predikterades endast 41 % av bildigenkänningsverktyget att med 76-100 % sannolikhet tillhöra klassen Ej planterbart (Figur 10). Samtidigt predikterades 31 % av provytorna att med 0-25 % sannolikhet tillhöra klassen Ej planterbart. Bildigenkänningsverktyget misslyckas därmed att identifiera ej planterbara och omärkberedda provytor i relativt hög utsträckning.

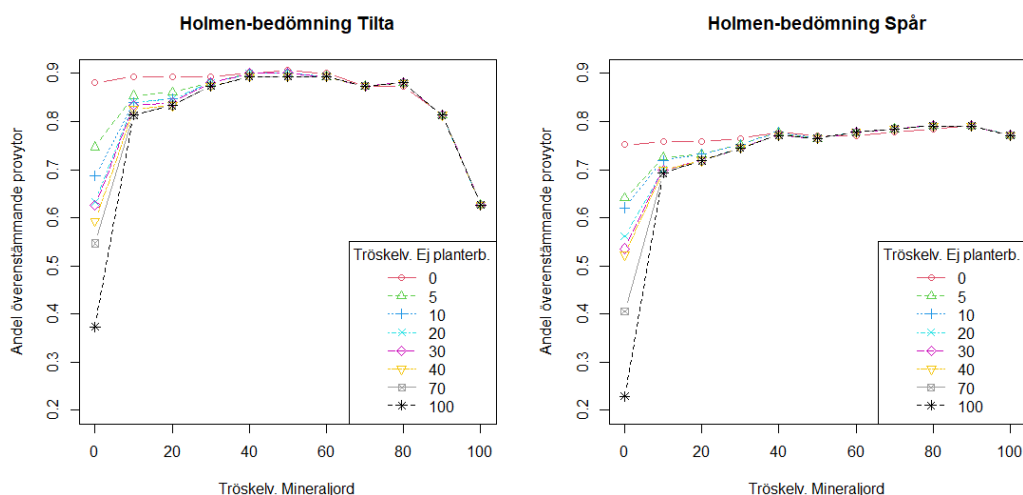


Figur 10. Andel provtytor i fält manuellt bedömda som omarkberedda och/eller ej planterbara fördelade på bildigenkänningsverktygets prediktioner (%) av klassen Ej planterbart.
Figure 10. Proportion of samples in field manually assessed as unprepared and/or not plantable distributed by the image recognition tool's predictions (%) of the class Not plantable.

3.3 Jämförelse av överensstämmelse i spår och tilta i mulet väder

3.3.1 Alla trakter tillsammans

Högre överensstämmelse med Holmen-bedömningen uppnås för provtytor i tilta än provtytor i spår. För tilta ges högst överensstämmelse, 97,0 %, vid tröskelvärdena Ej planterbart 0 %, och Mineraljord 50 % (Figur 11 t.v.). För spår ges högst överensstämmelse, 79,1 %, då tröskelvärde Mineraljord sätts till 90 % oavsett värde på Ej planterbart, eller alternativt då Mineraljord sätts till 80 % och Ej planterbart till minst 5 % (Figur 11 t.h.).



Figur 11. Andel överensstämmande provytor med Holmen-bedömningen för provytor i tilla respektive spår vid olika tröskelvärderna för klasserna Mineraljord och Ej planterbart.
Figure 11. Proportion of sample areas conforming to the Holmen assessment for sample areas in tilla and track respectively at different threshold values for the classes Mineral soil and Not plantable.

3.3.2 Skillnader mellan trakter

För trakterna Holmsjöväg, Lappmyran och Vålandsmyr uppnåddes högst överensstämming i tilla, medan högst överensstämmelse för trakten Storfors uppnåddes i spår (Tabell 7).

Tabell 7. Högsta överensstämmelse (%) med Holmen-bedömning för respektive trakt och för spår respektive tilla vid användning av prediktioner av klasserna Mineraljord och Ej planterbart som tröskelvärderna

Table 7. Highest agreement (%) with Holmen assessment for each site and for track and tilla when using predictions of the classes Mineral soil and Not plantable as threshold values

	Tilta	Spår
Holmsjöväg	97,3	84,4
Lappmyran	100	93,1
Storfors	91,3	92,0
Vålandsmyr	90,0	86,2

För trakterna Lappmyran och Vålandsmyr kan högsta överensstämmelse för både spår och tilla uppnås med samma inställning av tröskelvärderna (Tabell 8). För trakterna Holmsjöväg och Storfors krävs olika inställningar av tröskelvärderna.

För alla fyra trakter är det optimala tröskelvärdet för Ej planterbart relativt lika. Tröskelvärdet Ej planterbart 5-10 % fungerar för samtliga trakter i både spår och tilla (Tabell 8). Däremot varierar vilket tröskelvärdet på Mineraljord som krävs för att nå högsta överensstämmelse mellan 40-80 %. För trakten Storfors krävs tröskelvärdet Mineraljord 100 % för högsta överensstämmelse i spår, men Mineraljord 0 % i tilla.

Tabell 8. Tröskelvärden (%) för klasserna Mineraljord och Ej planterbart för högsta överensstämmelse med Holmen-bedömning per trakt för provytor i tilta respektive spår. Prediktioner godkänns för plantering om dessa är \geq tröskelvärdet för Mineraljord och \leq tröskelvärdena för Ej planterbart. För vissa trakter ges samma överensstämmelse vid flertalet kombinationer av tröskelvärden

Table 8. Threshold values (%) for the classes Mineral soil and Not plantable for highest agreement with Holmen assessment per site for sample areas in tilt and track respectively. Predictions are approved for planting if these are \geq the threshold for Mineral Soil and \leq the threshold for Not Plantable. For some site the same agreement is given at several combinations of thresholds

Trakt	Tilta		Spår	
	Mineraljord	Ej planterbart	Mineraljord	Ej planterbart
Holmsjöväg	80	0-100	40-70	0-100
Lappmyran	40	5-30	10-40 20-40	5 10
Storfors	0	5	100	0-100
Vålandsmyr	10-60 80	0	30-80 60-80	0 0-100

3.4 Effekt av ljusförhållanden

3.4.1 Tröskelvärden och solsken

Av samtliga provytor insamlade under soliga väderförhållanden bedömdes 44 % vara godkända (*Bra* eller *Optimal*) och 56 % underkända (*Övrig*) enligt Holmens instruktioner (Bilaga 1).

De optimala tröskelvärdena för mulna väderförhållanden som tagits fram i avsnitt 3.2 (Figur 9) ger sämre överensstämmelse på det separata datamaterial som togs fram med sol, halvskugga och skugga än redovisat i avsnitt 3.2. Som bäst uppnås 70,9-74,4 % överensstämmelse och då i skugga (Tabell 9). I solljus minskade detta med ca 5-7 procentenheter till 65,0 – 69,2 %. Halvskuggade provytor ger lägre överensstämmelse än skuggade men högre än i solsken. Det tyder på att överensstämmelsen blir sämre ju större del av provytan som blir solbelyst.

Tabell 9. Överensstämmelse med Holmen-bedömningen för respektive ljusförhållande vid användning av optimala tröskelvärden på klasserna Mineraljord och Ej planterbart för provtytor vid förhållanden utan sol (se 3.2). Till exempel "M40E0" motsvarar tröskelvärdena Mineraljord 40 % och Ej planterbart 0 %

Table 9. Agreement with the Holmen assessment for each light condition when using optimal threshold values for the classes Mineral soil and Not plantable for samples in conditions without sun (see 3.2). For example, "M40E0" corresponds to the threshold values Mineral soil 40 % and Not plantable 0 %

Ljusförhållande	M40E0	M40E5	M40E10	M50E0
Sol	65,8	68,4	69,2	65,0
Halvskugga	69,2	70,1	70,9	68,4
Skugga	72,6	73,5	74,4	70,9

4. Diskussion

4.1 Resultatdiskussion

Studiens resultat visar att vid användning av bildigenkänningsverktyget med optimerade tröskelvärden under mulna väderförhållanden bedöms planteringspunkterna i ca 80 % av fallen överensstämma med manuell fältbedömning enligt Holmen-bedömningen (Figur 9). Dessa tröskelvärden stöds även av ROC-analysen som gav att Mineraljord 40 % och Ej planterbart 0 % var de mest optimala tröskelvärdena för prediktionsklasserna som enskilda klassificerare av Holmen-bedömningen (Figur 5 och 6). Resultatet visar även att det inte är möjligt att använda klasserna Mineraljord och Ej planterbart som tröskelvärden för att öka överensstämmelsen mot Planterbart-bedömningen.

Målet med bildigenkänningsverktyget är att lyckas undvika dåliga planteringspunkter som exempelvis innehåller stor andel humus eller är omarkberedda. Tidigare studier har visat att vid plantering med Plantma X utan bildigenkänningsverktyget är planteringsresultatet sämre än vid manuell plantering, detta då tall planterats i harvfårar på moränmark (Tysklind 2021). De maskinellt planterade punkterna underkändes i den studien framför allt på grund av undermålig planteringspunkt, och en möjlig förklaring som gavs var planteringsmaskinens blindhet och medförande oförmåga att bedöma möjliga planteringspunkter. Senare studier (Dahlberg 2023) visar dock likvärdigt planteringsresultat av Plantma X och maskinell plantering. Denna studie visar att användning av bildigenkänningsverktyget med optimerade tröskelvärden har potential att förbättra planteringsresultatet för maskinell plantering med PlantmaX.

För Holmen-bedömningen är klasserna Mineraljord och Ej planterbart mest lämpliga som tröskelvärden, och för framför allt Mineraljord ger bildigenkänningsverktyget de säkraste prediktionerna. I teorin skulle vilka två av de tre klasserna som helst kunna användas för att uppnå högsta överensstämmelse eftersom prediktionerna av de tre summeras till 100 %. Vid användning av endast en av klasserna som tröskelvärde, eller att ytterligare möjliga klasser tillkommer, är klassens lämplighet som tröskelvärde viktig att ta i beaktning.

De optimerade tröskelvärdena för mulna väderförhållanden fungerar även för att uppnå högsta överensstämmelse för de enskilda trakterna. Att trakten Storfors

uppnår lägre överensstämmelse än de andra trakterna kan bero på att det var finkornig sedimentmark vilket var det som skiljde den från övriga trakter. Anledningen skulle till exempel kunna vara att mineraljorden därmed ser annorlunda ut och blir svårare att prediktera för verktyget. I och med att denna trakt var på sedimentmark skiljde även kraven på *Bra* planteringspunkt enligt instruktionerna för Holmens uppföljning sig åt från övriga trakter. Skillnaden kan därför även bero på detta eftersom punkter med humus kan godkännas på sådana marker.

Bortsett från trakten Storfors, ges högre överensstämmelse då tröskelvärdena optimeras både för respektive trakt och för spår respektive tilta. Att högre överensstämmelse uppnås för provytor i tilta än i spår kan innebära att markberedningsinställningar som används vid plantering i tilta ger ”renare” provytor och därför blir lättare för bildigenkänningsverktyget att prediktera. Att Storfors är avvikande även i detta avseende beror troligtvis även det av ovan redan nämnda anledningar, och tyder på att studiens resultat främst är giltiga för marker med sandig-moig morän. Trots det presterar verktyget relativt bra även på annan mark.

Utifrån de tröskelvärden som testats i denna studie är det i större delen av fallen möjligt att vid mulna väderförhållanden uppnå likvärdig överensstämmelse (cirka 83 %) genom ett relativt brett spann av tröskelvärden (Figur 7). Överensstämmelsen är känsligast för vilket tröskelvärde som sätts för Ej planterbart då tröskelvärdena för Mineraljord är låga (ca 0-20 %). Det viktigaste tycks vara att tröskelvärdet för Ej planterbart är lägre än 100 %, och att vid låga tröskelvärden för Mineraljord också ha låga tröskelvärden för Ej planterbart.

Fysiskt ej planterbara planteringsytor undviks redan med hjälp av marksensorer. Bildigenkänningsverktyget visades vara relativt ineffektivt för att undvika plantering i sådana omarkberedda och ej planterbara ytor. Troligtvis beror detta på att verktyget har svårast att skilja mellan prediktionsklasserna Humus och Ej planterbart och att dessa förväxlas med varandra. Trots detta ganska dåliga resultat av verktygets prediktion av Ej planterbart så tillför ändå ett tröskelvärde på högst 10 % till högre överensstämmelse (Figur 7). Då verktyget i denna aspekt är bristande är de redan existerande marksensorerna fortsatt viktiga för att välja bort ej planterbara planteringspunkter.

Solljus orsakar, troligtvis genom skuggbildning, en försämring av bildigenkänningsverktygets prediktioner i jämförelse med mulna väderförhållanden. Denna försämring ökar ju större del av ytan som är solbelyst. Anledningen till försämringen är att bildverktygets prediktioner av klasserna Humus och Ej planterbart blir signifikant olika i sol och skugga, vilket kan tyda på att dessa två klasser blandas ihop i högre grad av verktyget vid solljus. Dock ger bildigenkänningsverktyget en förbättring av valet av planteringspunkter även i solljus. Det har gjorts försök att minska solljusets påverkan på verktygets

prediktioner genom att använda stark belysning på ytan som kameran fotograferar, men detta gav endast en mycket begränsad förbättring (Johansson pers. komm. 2022-09-07).

I denna studie användes en annan kamera än den som används i verktyget. Studien är principiell och bilderna har anpassats till att motsvara de som tas av verktyget i den mån det var möjligt. De viktigaste anpassningarna var att bilderna fotograferades linjärt (utan vidvinkelfunktioner) och att utgå från samma upplösning. Bilderna togs i en högre upplösning och konverterades i efterhand till att motsvara den lägre upplösningen som används i verktyget. Detta steg sker inte i verktyget och är något som skulle kunna ha en mindre påverkan genom en viss kvalitetsförlust i bilderna. Denna minimerades genom att fotografera i en multipel av den önskade upplösningen (256 x 256 pixlar). Anledningen till den låga upplösningen är att verktyget ska hinna bedöma 8 bilder per sekund. Även om risken har minimerats finns det en viss osäkerhet i om detta påverkat hur modellen bedömer bilderna. Inga sådana skillnader har dock observerats och risken antas därmed vara låg. Olika kameror hanterar ljuskontraster och färgåtergivning olika bra vilket skulle kunna vara en påverkande faktor för hur väl verktygets modell presterar om detta skiljer sig mycket åt från verktygets kamera.

Ett problem med maskinen är att det i dagsläget inte finns någon funktion som ser till att plantantalet blir korrekt i de fall då inte tillräckligt många planteringspunkter godkänns av bildigenkänningsverktyget. Maskinen är jämfört med manuell plantering inte heller lika flexibel i och med att inställningarna ställs in att plantera antingen i spår eller tilla. En manuell plantör kan däremot välja att plantera i spår om ingen tillfredsställande planteringspunkt är möjlig i tiltan. Ett sätt att hantera problemet skulle kunna vara att verktygets tröskelvärden automatiskt sänks baserat på vad avståndet till senast satta planta är. En annat sätt kan vara att, i och med att 8 bilder per sekund bedöms av verktyget, kräva att ett visst minimum antal bilder i sträck ska bedömas vara underkända innan planteringen upphör.

Verktyget skulle kunna utvecklas genom att använda metoden *semantic segmentation* i stället för *multiclass classification*. Med den metoden skulle det potentiellt vara möjligt att urskilja de olika klasserna i olika regioner av bilden. Det skulle i sin tur göra det möjligt att bedöma hur stor andel av respektive klass som bilden består av och då ställa in tröskelvärden som representerar andelen av klasserna i stället för sannolikheten att hela bilden består av respektive klass. Inledningsvis var det denna metod var den som användes för att ta fram verktyget, men visades vara för tidskrävande inom projektets ramar.

Då verktyget fortfarande är under utveckling är det möjligt att osäkerheter i AI-modellen finns. Uppbyggnaden av AI-modellen och dess svagheter har inte undersökts i denna studie och kan därför inte sägas något om i detalj. Eftersom modellen endast är tränad på en begränsad mängd bilder skulle en möjlighet att öka dess noggrannhet vara att träna systemet på en större mängd bilder.

4.2 Metoddiskussion

Det finns flera styrkor med valet av metod i studien. En viktig del är att studien utförts med ett omfattande dataset och att påverkan från yttre faktorer reducerades i största möjliga mån genom att studien genomfördes oberoende av planteringsmaskinen. All datainsamling är utförd av samma person på alla trakter vilket ger en likvärdig datainsamling. För den manuella fältbedömningen hade det dock funnits större säkerhet i vilken grad denna referensbedömning påverkas av vem som utför den ifall att flertalet inventerare utfört samma bedömningar och gett möjlighet att analysera spridningen på dessa. Detta var för resurskrävande för att vara möjligt inom ramen för denna studie. Trots denna osäkerhet bygger fältbedömningen ändå på tydliga kriterier (Tabell 2). Det centrala i denna studie är dessutom att få fram en bedömning av om punkten är lämplig för att planteras i eller ej snarare än att värdera hur bra den är. Det spelar till exempel ingen roll om en provyta är bedömd som optimal eller bra eftersom båda bedöms som lämpliga planteringspunkter. Då den manuella bedömningen i fält utförts enligt förutbestämda instruktioner är studien upprepbar. En förutsättning är dock att bildigenkänningsverktyget inte har ändrats. Då det är under utveckling är det troligt att bedömningen från verktyget ger ett något annorlunda resultat om studien skulle upprepas på samma punkter.

En möjlig alternativ metod kan vara att i stället använda sig av provytor som det maskinmonterade bildigenkänningsverktyget redan bedömt. Ett sådant upplägg hade krävt en mycket noggrann GPS för att återfinna provytan på bilden i fält. Det hade skapat osäkerhet i om bildigenkänningsverktyget och fältbedömningen bedömt samma provyta. Med den maskinoberoende metoden som används kunde också kamerans höjd och provytans storlek kontrolleras mer noggrant och på så sätt få likvärdiga bilder.

De optimerade tröskelvärdena validerades genom att testas för de skuggade provytorna i soltripletterna och visades ge något sämre överensstämmelse än för de provytor de optimerats för. Denna validering indikerar att tröskelvärden kan behöva justeras en del beroende på olika förhållanden. Hur den justeringen borde vara är dock inget som denna studie besvarat.

För att undersöka effekten av markfuktighetsklass på bildigenkännings prediktioner hade troligtvis Skogforsks instruktioner för uppföljning av Plantma X kunnat vara ett bättre val för analyserna än Holmens uppföljningsinstruktioner. Detta eftersom Skogforsks instruktioner, till skillnad från Holmens, inte gör skillnad i kriterierna för godkänd eller inte godkänd planteringspunkt för fuktig respektive torr/frisk markfuktighetsklass. Därmed hade eventuellt slutsatser kunnat dras om hur markfuktighetsklass påverkar bildigenkänningsverktygets resultat. I och med att Holmens uppföljningsinstruktion har kriterier som gör skillnad på marktyper kan slutsatser inte dras om resultatet beror av denna skillnad i kriterierna eller av bildigenkännings prediktion på sådana marktyper. Dock blir studiens

resultat och slutsatser ändå begränsade till relativt liten variation av marktyper och fuktighetsförhållanden, och inga slutsatser kan dras om hur detta påverkar bildigenkänningsverktygets prediktioner.

I denna studie där två av tre prediktionsklasser används som tröskelvärden i bildigenkänningsverktyget kan lika överensstämmelse ges oavsett vilka två av dem som används, i och med att prediktionerna summerar upp till 100 (undantaget avrundningsfel som i vissa fall kan innebära minimal skillnad). I fall av att ytterligare prediktionsklasser analyseras av bildigenkänningsverktyget blir dock ROC-analyserna viktiga för att kunna utreda vilka av dem som är mest lämpade som tröskelvärden.

Studiens datamaterial innehåller en stor andel underkända provytor, vilket är en viktig förutsättning för att genom analyserna kunna undersöka möjligheten att undvika sådana planteringspunkter med hjälp av verktyget. Ytterligare en styrka att relativt många provytor under soliga förhållanden lyckades samlas in, och att dessa var relativt jämnt fördelade mellan trakterna, vilket gav möjlighet att undersöka hur ljusförhållandena påverkar bildigenkänningsverktygets prestanda.

Studien är begränsad till den typ av markberedning som Plantma X ger då den kör över tiltan med bakre vagnen, vilket skiljer resultatet från en konventionell markberedare. Resultatet är därför inte generaliserbart för alla typer av markberedningsmetoder.

Bildigenkänningsverktyget är än så länge endast tränad med bilder insamlade under sommaren. I och med att förhållanden under olika årstider kan innebära annan färg och struktur på mark och växtlighet i provytorna, kan verktygets prediktioner påverkas. Även solljusförhållandena varierar med årstiden. Resultatet kan därför bli annorlunda beroende på årstid vid utförandet och studien blir därmed begränsad till att visa hur väl verktyget fungerar under höstsäsongen.

En ytterligare svaghet med studien är att resultatet endast visar hur väl bildigenkänningsverktyget presterar på ett begränsat antal trakter, marktyper och geografiskt område.

4.3 Fortsatta studier

Det är möjligt att andra faktorer än de som undersökts i denna studie påverkar bildigenkänningsverktygets prediktioner av planteringspunkter. Markens fuktighet är en möjlig sådan faktor då utseendet på alla tre av klasserna som verktyget predikerar kan förändras beroende på om marken är torr eller blöt. Det är därför av intresse att undersöka hur stor den påverkan är och om det finns eventuella interaktionseffekter med ljusförhållande. Detta skulle då kunna genomföras med liknande metod på ett kontrollerat sätt genom att konstgjort styra fuktigheten på marken. En del av materialet i denna studie är insamlat under förhållanden med

regn. Påverkan av detta har i denna studie inte undersökts och inga uppenbara skillnader av detta har noterats. Detta är något som bör analyseras i fortsatta studier.

Det bör även undersökas vidare hur verktyget fungerar på olika typer av marker vilket inte kunde göras i tillräcklig omfattning i denna studie. Dock bör det tänkta användningsområdet för maskinen där tas i beaktning, så att endast marktyper som maskinen planeras att användas för undersöks för att sedan kunna få praktisk användning av resultatet.

Nyttan av bildigenkänningsverktyget bör styrkas genom vidare studier där planteringsresultatet vid plantering med Plantma X och användning av bildigenkänningsverktyget jämförs mot planteringsresultatet vid plantering med Plantma X utan användning av det.

Fortsatta studier bör även jämföra resultatet av plantering med maskinell plantering med Plantma X med bildigenkänningsverktyget med planteringsresultat vid manuell plantering.

Det finns även potential i att utveckla verktyget för ytterligare användningsområden, som exempelvis för andra typer av automatiserande planteringsmaskiner.

Vid användning av samma eller liknande referensmätning i framtida studier bör osäkerheten i dessa kvantifieras för att kunna dra slutsatser om påverkan på studiens resultat.

4.4 Förbättringspotential genom kombination med mekanisk avkänning av hinder

De allra sämsta planteringspunkterna, alltså de som inte är planterbara på grund av exempelvis stubbar och stenar, undviks redan med hjälp av sensorer i planteringsarmarna. Då bildigenkänningsverktyget används tillsammans med planteringsarmarnas sensorer finns potential att förbättra planteringsresultatet ytterligare. Planteringsmaskinens fullständiga potential att undvika dåliga planteringspunkter genom användning av både bildigenkänningsverktyget och den mekaniska marksensorn i planteringsarmarna kan i teorin uppskattas genom att göra antagandet att marksensorn förhindrar plantering i alla provytor som i fält är manuellt bedömda som ej planterbara. Om överensstämmelsen då beräknas på samma sätt som tidigare, men med skillnaden att samtliga provytor som i fält är bedömda ej planterbara provytor räknas som underkända oavsett vad bildigenkänningsverktyget, skulle det vid användning av optimerade tröskelvärden vid mulna väderförhållanden då ges en överensstämmning på 87,5 – 90,1 % (Tabell 10). Detta innebär 4 - 6,3 %-enheter högre överensstämmelse i jämförelse med användning av endast bildigenkänningsverktyget. För tillfället är därmed en

kombination av bildigenkänningsverktyget och marksensorerna det som uppnår bäst överensstämmelse.

Tabell 10. Överensstämmelse med Holmen-bedömningen vid användning av endast bildigenkänning och användning marksensor och bildigenkänning tillsammans. Marksensor innebär att provytor i fält bedömda som ej planterbara inte planteras, och provytor bedömda som planterbara blir planterade. Gäller för användning av bildigenkänning med de mest optimala tröskelvärdena för alla trakter tillsammans (M40E0, M40E5, M40E10, M50E0)

Table 10. Agreement with the Holmen assessment when using only image recognition and when using ground sensor and image recognition together. Ground sensor means that samples in the field assessed as not plantable are not planted, and samples assessed as plantable are planted. Applies to using image recognition with the most optimal threshold values for all sites together (M40E0, M40E5, M40E10, M50E0)

Använda verktyg	Överensstämmelse (%)
Bildigenkänning	83,8
Marksensor och bildigenkänning	87,5 –90,1

4.5 Slutsatser

- Hypotesen att justering av tröskelvärdena kan förbättra överensstämmelsen mot fältbedömningen kan antas. Optimala inställningar av tröskelvärden ger ca 80 % överensstämmelse mot fältbedömning. Överensstämmelsen kan förbättras ytterligare då tröskelvärdena optimeras för respektive trakt och om verktyget kombineras med Plantma X marksensorer.
- Hypotesen att solljus och medförande skuggbildning kommer att påverka bildigenkänningsverktygets bedömning negativt kan antas då både ljusförhållanden i solljus och halvskugga gav lägre överensstämmelse än fullt skuggade förhållanden.
- Av de tre prediktionsklasserna Mineraljord, Humus och Ej planterbart ger bildigenkänningsverktyget bäst prediktion av sannolikheten för Mineraljord, även under soliga väderförhållanden. Mineraljord fungerar därför bäst som enskilt tröskelvärde, men överensstämmelsen kan förbättras ytterligare genom att kombinera det med ett tröskelvärde för Ej planterbart.
- Hypotesen att högre överensstämmelse nås i det mer homogena spåret än i tiltan kan förkastas. I huvudsak uppnås bättre överensstämmelse mot fältbedömning vid markberedning i tilta än i spår. Dock finns osäkerheter kring hur detta förhållande är för finkorniga sedimentmarker på grund av att resultaten för trakten Storfors med sådan mark var avvikande från övriga trakter med sandig-moig morän. Om detta beror av marktypen eller av fältbedömningen går inte att dra någon slutsats om i denna studie.

- Det är möjligt att använda bildigenkänningsverktyget för att undvika en betydande andel dåliga planteringspunkter. Detta är dock ett förbättringsområde då endast ca 60 % av de omarkberedda och ej planterbara planteringspunkterna bedöms av verktyget att med minst 50 % sannolikhet vara ej planterbara. En del av sådana planteringspunkter undviks redan med marksensorer på Plantma X. Denna analys bygger på en manuell plantörs bedömning och det är svårt att bedöma hur stor osäkerheten är.
- Bildigenkänningsverktyget är ett steg på vägen mot ett automatiserat val av planteringspunkter men fortsatt utvecklingsarbete krävs för att fungera bättre i solsken. Det kan även finnas andra förhållanden som inte studerats i denna studie, till exempel olika marktyper eller hur blöt marken är, som kan ha påverkan på hur väl verktyget fungerar.

Referenser

- Bourel, M. & Segura, A.M. (2018). Multiclass classification methods in ecology. *Ecological indicators*, 85, p.1012–1021.
- Dahlberg, S. (2023). *Jämförelse av planteringsresultatet mellan markberedningsmetoderna harvspår och omvänd torva för planteringsmaskinen Plantma X*. (2023:2) Sveriges lantbruksuniversitet. Skogens biomaterial och teknologi/Jägmästarprogrammet. <https://stud.epsilon.slu.se/18703/>
- Ersson, B.T. (2010). *Possible concepts for mechanized tree planting in southern Sweden - an introductory essay on forest technology*. (Arbetsrapport / Sveriges lantbruksuniversitet, Institutionen för skoglig resurshushållning 2010:269) Umeå: Sveriges lantbruksuniversitet, Institutionen för skoglig resurshushållning. <https://res.slu.se/id/publ/28674>
- Ersson, B.T. (2014). *Concepts for mechanized tree planting in southern Sweden*. Diss. Umeå: Sveriges lantbruksuniversitet. Acta Universitatis agriculturae Sueciae (2014:76). <https://res.slu.se/id/publ/60997>
- Ersson, B.T. (2022). *Maskinell plantering – analys av planteringsmaskinen PlantmaX potential inom privatskogsbruket*. (SLU Skogsmästarskolans Rapportserie 2022:1). Skinnskatteberg: Skogsmästarskolan, Sveriges lantbruksuniversitet <https://res.slu.se/id/publ/115788>
- Forsmark, V. & Johannesson, T. (2020). *Skogsvårdsföretagens rekrytering – förutsättningar, nuläge och konsekvenser*. (Arbetsrapport 1039-2020). Uppsala: Skogforsk. https://www.skogforsk.se/cd_20200213104712/contentassets/5a02e26f45644279b7a4651f98c8cdbf/arbetsrapport-1039-2020.pdf
- Hallonborg, U. (1997). *Aspects of mechanized tree planting*. Diss. Institutionen för skogsteknik. Uppsala: Sveriges lantbruksuniversitet. ISBN: 9157653135
- Hallonborg, U., von Hofsten, H., Mattsson, S. & Thorsén, Å. (1997). *Planteringsmaskiner i skogsbruket – en beskrivning av metoder och maskiner*. (Redogörelse - Skogforsk, 1103-4580; 1997:7). Uppsala: Skogforsk.
- Hallsby, G. (2013). *Skogsskötselserien 3 - Plantering av barrträd*. 2 uppl., Jönköping: Skogsstyrelsen. <https://www.skogsstyrelsen.se/globalassets/mer-om-skog/skogsskotselserien/skogsskotsel-serien-3-plantering-av-barrtrad.pdf>
- Jordan, J. (2018). An overview of semantic image segmentation. *Data science*. [Blogg]. 21 maj. <https://www.jeremyjordan.me/semantic-segmentation/> [2022-09-14]
- Malmberg, C.E. (1990). *Mekanisering av skogsodling*. Stockholm: Styrelsen för teknisk utveckling.

- Manner, J. & Ersson, B.T. (2021). Mechanized tree planting in Nordic forestry: Simulating a machine concept for continuously advancing site preparation and planting. *Journal of forest science*. 67(5), p.242-246.
- Nahm, F.S. (2022). Receiver operating characteristic curve: overview and practical use for clinicians. *Korean journal of anesthesiology*, 75(1), p.25–36.
- Nationalencyklopedin (u.å). *Artificiell intelligens*.
<https://www.ne.se/uppslagsverk/encyklopedi/l%C3%A5ng/artificiell-intelligens>
 [2022-09-14]
- Patil, A.N. (2021). Image recognition using machine learning. *International Journal of Engineering Applied Sciences and Technology*. 1(6), p. 195-198.
- Plantma forestry (u.å. a). *Detta är Plantma X*. <https://plantmaforestry.com/sv/detta-ar-plantma-x/> [2022-09-13]
- Plantma forestry (u.å. b). *Huvudkomponenter*.
<https://plantmaforestry.com/sv/huvudkomponenter/> [2022-09-13]
- Plantma forestry (u.å. c). *Om oss*. <https://plantmaforestry.com/sv/om-oss/> [2022-09-13]
- Plantma forestry (u.å. d). *Så funkar det*. <https://plantmaforestry.com/sv/sa-funkar-det/>
 [2022-09-13]
- Ramantswana, M., Guerra, S.P.S., & Ersson, B.T. (2020). Advances in the Mechanization of Regenerating Plantation Forests: a Review. *Current forestry reports*. 6(2), p.143-158.
- Robin, X., Turck, N., Hainard, A., Tiberti, N., Lisacek, F., Sanchez, J., and Müller, M. (2011). pROC: an open-source package for R and S+ to analyze and compare ROC curves. *BMC Bioinformatics*. 12, p.77.
- Sundström, N. (2022). Ny maskin jobbar dubbelt. *Skogsliv*, (2), p. 32-34.
<https://www.holmen.com/sv/skog/att-aga-skog/skogsliv/> [2023-02-13]
- Skogforsk (2020). *Kunskapsbanken - Attityder till markberedning*. (Nr 20-2020).
<https://www.skogforsk.se/kunskap/kunskapsbanken/2020/attityder-till-markberedning/> [2023-02-13]
- Skogforsk (2022). *Kunskapsbanken - Mekanisk planteringsmaskin lär sig "se" var plantan ska sättas*.
<https://www.skogforsk.se/kunskap/kunskapsbanken/2022/planteringsmaskin-lar-sig-se-var-plantan-ska-sattas/> [2023-02-14]
- Skogsstyrelsen Statistikdatabas (2022a). *Återväxternas kvalitet. 01. Använd förnygringsmetod, som andel (%) av avverkad areal efter landsdel och förnygringsmetod. År (treårsmedelvärde) 2000- .* Skogsstyrelsen.
http://pxweb.skogsstyrelsen.se/pxweb/sv/Skogsstyrelsens%20statistikdatabas/Skogsstyrelsens%20statistikdatabas__Atervaxternas%20kvalitet/JO0311_1.px/
- Skogsstyrelsen Statistikdatabas (2022b). *Åtgärder i skogsbruket. 03. Maskinell markberedning (1 000 ha) efter ägarklass och region. År 2005-2021.* Skogsstyrelsen.
http://pxweb.skogsstyrelsen.se/pxweb/sv/Skogsstyrelsens%20statistikdatabas/Skogsstyrelsens%20statistikdatabas__Atgarder%20i%20skogsbruket/JO16_03%20-%20Markberedning.px/

- Tysklind, L. (2021). *Maskinell plantering med Plantma X : terrängegenskapernas påverkan på planteringsmaskinens planteringsresultat*. (2021:7) Sveriges lantbruksuniversitet. Skogens biomaterial och teknologi/Jägmästarprogrammet. <https://stud.epsilon.slu.se/17291/>
- Wang, Y., Dang, L. & Ren, R. (2019). Forest fire image recognition based on convolutional neural network. *Journal of Algorithms & Computational Technology*. 13.
- Wang, Y., Zhang, W., Gao, R., Jin, Z. & Wang, X. (2021). Recent advances in the application of deep learning methods to forestry. *Wood science and technology*. Vol.55 (5), p.1171-1202.

Personlig kommunikation

Johansson, Jan. Forskare Driftsystem. Skogforsk. 2022-09-07 och 2023-03-06.

5. Bilaga

Fördelningen av antal provytor enligt Holmen Skogs uppföljningsinstruktion för manuell plantering.

	Optimal	Bra	Övrig	Totalt
Mulet				
Vålandsmyr	2	17	40	59
- Därav i spår	0	13	16	29
- Därav i tilta	2	4	24	30
Holmsjöväg	7	18	57	82
- Därav i spår	0	12	33	45
- Därav i tilta	7	6	24	37
Lapmyran	1	14	51	66
- Därav i spår	0	6	23	29
- Därav i tilta	1	8	28	37
Storfors	1	31	64	96
- Därav i spår	0	4	46	50
- Därav i tilta	1	27	18	46
Provytor då mulet	11	80	212	303
Sol				
Vålandsmyr	1	20	19	40
- Därav i spår	0	12	7	19
- Därav i tilta	1	8	12	21
Holmsjöväg	2	12	27	41
- Därav i spår	0	9	12	21
- Därav i tilta	2	3	15	20
Lapmyran	0	0	4	4
- Därav i spår	0	0	3	3
- Därav i tilta	0	0	1	1
Storfors	0	14	18	32
- Därav i spår	0	1	16	17
- Därav i tilta	0	13	2	15
Provytor då sol	3	46	68	117
Totalt	14	126	280	420