

# Skogliga skattningar med flygbilder och skördardata



## Förord

Denna rapport sammanfattar ett utvecklingsprojekt finansierat av Skogssällskapet som genomförts under åren 2016-2018. Projektet visar hur skördardata kan användas som markreferens för fjärranalysskattningar av skogliga parametrar som grundyta och virkesvolym. En väsentlig utgångspunkt är tillgången till skördardata och den skördardatabas för forskningsändamål som Skogforsk byggt upp. Liknande databaser byggs nu inom respektive skogsföretag vilket gör det möjligt att sprida tillämpningar som använder skördardata. Detta projekt har använt skördardata från Södra och Sveaskog vilket företagen välvilligt ställt till förfogande för projektet. Sveaskog har även bidragit med utvärderingsdata i form av objektiva provytor som samlades in för en företagstaxering. Stort tack till alla inblandade!

Umeå den 28 februari 2018

Jörgen Wallerman, SLU

Erik Willén, Jon Söderberg, Johan Möller, Skogforsk

## Innehåll

Innehåll .....	3
Sammanfattning.....	4
Bakgrund.....	5
Syfte och mål .....	5
Material och metod .....	7
Studieområde.....	7
Fjärranalysdata.....	7
Skördardata.....	8
Utvärderingsdata .....	8
Metod .....	9
Introduktion .....	9
Imputering.....	10
Deep Learning.....	10
Utvärdering.....	11
Resultat.....	13
Imputering.....	13
Deep Learning.....	16
Diskussion och slutsatser.....	18
Referenser .....	20

## Sammanfattning

Behovet av geografiska data för den svenska skogen ökar ständigt, speciellt efter Lantmäteriets nationella flygburna laserskanning år 2009 – 2014 som, via ett samarbete mellan Skogsstyrelsen och Sveriges lantbruksuniversitet med referensdata från Riksskogstaxeringen, gjorde noggranna skattningar av skogliga parametrar tillgängliga för alla skogsägare. Skogliga Grunddata utnyttjas av hela skogssektorn för att förbättra den skogliga planeringen och levererar noggranna beslutsunderlag för en stor mängd olika tillämpningar som inte tidigare funnits. Idag är däremot Skogliga Grunddata på väg att bli inaktuellt eftersom laserskanningen inte upprepats och det söks efter andra datakällor för att uppdatera databasen. Den främsta, befintliga ersättaren för flygburen laserskanning är stereomatchning av flygbilder, som i likhet med laserskanning levererar tredimensionella (3D) data över trädsiktet, men med något lägre kvalitet. Skördardata har sedan tidigare visat sig vara en mycket bra källa för referensinformation om skogen och speciellt som operativt användbar i kombination med data från flygburen laserskanning för att prediktera utfallet av planerade avverkningar. Skördardata fungerar i detta fallet som en ersättning av referensdata i form av inventerade provytor. Detta bör vara en mycket kostnadseffektiv metod att beräkna rasterskattningar med eftersom det ersätter dyra inventeringar av provytor. Projektet har fokuserat på metoder att producera rasterskattningar av skogstillståndet med hjälp av skördardata i kombination med stereomatchade flygbilder, som en mycket kostnadseffektiv metod att löpande producera uppdaterade, heltäckande rasterskattningar av skogstillståndet. Lantmäteriets nya standardprodukt ”Ytmodeller från flygbilder”, dvs 3D-data från stereomatchning av flygbilder, har använts i kombination med skördardata från Sveaskog och Södra i ett studieområde öster om Växjö. Två olika skattningsmetoder har utvecklats och utvärderats, dels den befintliga och beprövade imputeringsmetoden som idag används för laserskanningsdata och även en första tillämpning av en ny metod, Deep Learning, från forskningsfältet Artificiell Intelligens / Machine Learning. Den senare metoden förväntas vara mycket väl lämpad för storskalig kartering med fjärranalys och skördardata eftersom den är designad för att utnyttja enorma datamängder för automatiska, komplexa skattningar. Projektet visar goda resultat, kombinationen av skördardata och stereomatchade flygbilder producerade bara något sämre resultat än om laserskanningsdata använts. Deep Learning levererade också rimliga resultat, men klart sämre än den etablerade imputeringsmetoden. Det finns däremot mycket stor förbättringspotential för den modell som utvärderades här, dels är projektets datamaterial sannolikt för litet för en effektiv beräkning, och dels behöver en betydligt större utvecklingsinsats för att hitta en Deep Learning-modell som fungerar bra för just denna tillämpning.

## Bakgrund

Under 2015 avslutade Skogsstyrelsen arbetet med Skogliga Grunddata – en nationell kartering av skogliga data (parametrarna trädhöjd, grundyta, medeldiameter och virkesvolym) baserat på Lantmäteriets laserdata och Riksskogstaxeringens inventeringsdata. Fjärranalysskattningar av skogliga parametrar kräver referensdata från fält. Skördardata som fältreferens ger betydligt lägre kostnader än fältinventeringar och standardiserade skördardata samlas in kontinuerligt. De kan sedan användas i etablerade metoder för värdeskapande skattning av skogstillståndet från fjärranalys. Med tillgång till heltäckande, aktuella och noggranna data över skogen kan planeringen av skogsbruket förbättras avsevärt. Dessutom kan produktionskostnaderna för nya skogsbruksplaner sänkas då en stor del av mätningarna i fält kan ersättas, samtidigt som systematiska fel från subjektiva inventeringsmetoder undviks. Mer tid kan användas i fält till att bestämma och korrigera de egenskaper som inte enkelt kan skattas med fjärranalys, såsom avdelningsgränser, trädslagsblandning och skötselalternativ.

Lantmäteriets laserskanning utfördes i huvudsak under perioden 2009 – 2014, detta innebär att data för stora delar av landet börjar bli inaktuellt, framförallt i södra Sverige. Den nya laserbaserade markmodellen har gett helt nya möjligheter att använda flygbilder för att producera likartad information om skogens tillstånd som laserskanning kan ge, dvs. tre-dimensionella (3D) data med noggrann information om framförallt trädhöjd. Flygbilderna i kombination med markmodellen kan ge tillförlitliga trädhöjder. Med stereomatchning av Lantmäteriets flygbilder och markmodellen har forskning vid SLU visat skattningsnoggrannheter av skogliga data ungefär motsvarande Skogliga Grunddata. Metoden är på stark framfars och Lantmäteriet har under 2015 gjort en pilotproduktion och distribuerar idag trädhöjdsraster från stereomatchning av flygbilderna från 2015 och därefter.

Skördardata samlas in kontinuerligt för i stort sett alla avverkningar i Sverige. Data lagras enligt StanForD standarden (Arlinger et al. 2012), vilket möjliggör att de kan nyttjas in i en rad olika tillämpningar. De senaste åren har gallringsuppföljning (Hannrup et al. 2015, Möller et al. 2011) med skördardata och olika verktyg för produktionsuppföljning implementerats och mer utveckling pågår bland annat för att använda det som referensdata för skattningar av virkesutfall enligt hprYield metoden (pers ref Bhuiyan 2015). Möjligheten finns även att beskriva den kvarvarande skogen efter gallring. I samarbete mellan SLU och Skogforsk har skördardata kombinerats med laserdata för att kartera skogliga parametrar och visat mycket goda resultat (Holmgren et al. 2012; Söderberg 2015). Skogforsk har utvecklat nya verktyg för att enkelt sammanställa skördardatafiler, Dessa verktyg gör det praktiskt möjligt att hantera data från den egna verksamheten och geografiskt koppla detta till fjärranalysdata och producera tematiska kartor.

## Syfte och mål

Syftet med projektet är att förbättra dataförsörjningen till skogsbruket genom att utnyttja de nya möjligheter som finns att använda befintliga och noggranna

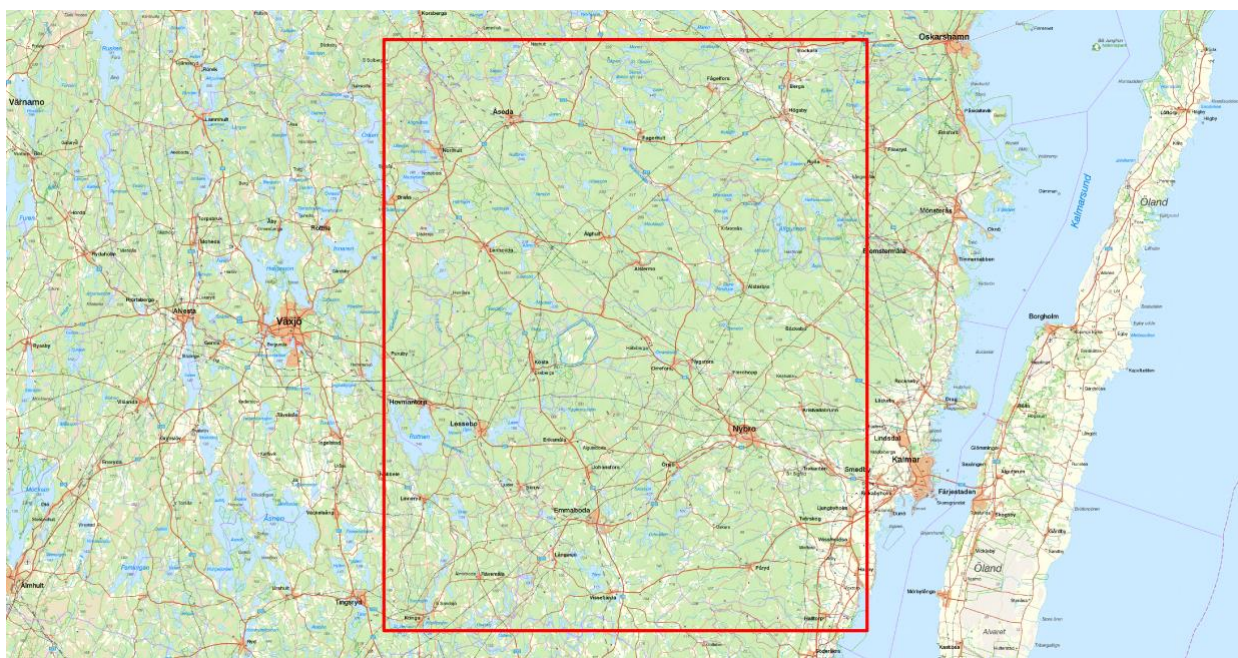
datakällor till kostnadseffektiv fjärranalysbaserad kartering av skogliga data. För att fånga den skogliga variationen bättre än med beståndsmedelvärden blir karteringen yttäckande. Speciellt intresse riktas mot små och medelstora skogsägare som ännu inte kunnat motivera kostnaderna för att använda modern fjärranalys i sin verksamhet. Projektets resultat förväntas generera nya möjligheter för värdeskapande planering av kundkommunikation, avverkning, skogsskötsel och naturvård.

Projektets mål var att ta fram en mycket kostnadseffektiv metod att producera aktuella rasterskattningar av skogliga data baserat på den löpande insamlingen av flygbilder och skördardata. Metoden utvärderades tillsammans med skogsföretag i Götaland mot nyligen gjorda kontrolltaxerade beståndsdata samt objektiva skördarmätningar på beståndsnivå. De skogliga parametrar som karterades är grundyta, grundytvägd medelhöjd, grundytvägd medeldiameter och stamvolym per hektar.

# Material och metod

## Studieområde

Studieområdet var beläget öster om Växjö (Figur 1) med en area om drygt 6000 km<sup>2</sup> för att inkludera en bedömd tillräckligt stor mängd av skördardata för att fånga den skogliga variationen. Området valdes även då fjärranalysdata i form av flygbilder var registrerade samma år över hela området.



Figur 1. Studieområde.

## Fjärranalysdata

Studieområdet omfattades av Lantmäteriets ordinarie omdrevsfotografering som genomfördes 2016-04-11 till 2016-04-12 med mätkameran Ultracam Eagle och levererade IR-flygbilder med en pixelstorlek av 0,24 m. Lantmäteriet genomför idag en löpande stereomatchning av alla nya flygbilder till en ny produkt, ”Ytmodell från flygbild” (Lantmäteriet, 2018), vilket användes för detta projekt. Produkten innehåller en höjd över havet för varje punkt i ett regelbundet grid med 0,5 m avstånd mellan näraliggande punkter, och är beräknade med semi-global stereomatchning av flygbilderna i programvaran SURE (Lantmäteriet, 2018; Rothmel et al., 2012).

Lantmäteriets ordinarie markhöjdsmodell användes inom projektet för att beräkna ett flertal variabler som bör beskriva ståndortsegenskaper som exponering och markfuktighet. Dessa variabler är idag enkla att beräkna med en nationell täckning och har sannolikt en potential att förbättra skattningsnoggrannheten för storskalig kartering baserad på fjärranalys och så detaljerade data som skördarsystemen levererar. Två olika mått som beskriver markfuktigheten beräknades från Lantmäteriets laserskannade markmodell: depth-to-water (Leach et al., 2017), topographic wetness index (Sørensen et al.,



2006), och en klassificering av markens lutningsförhållanden relaterat till dess omgivande landskap: Pennocks klassificering (Pennock et al., 1987). För den senare beräknades lutningsklasser för fyra olika spatiala upplösningar: 50, 30, 20 och 10 m.

## Skördardata

Södra och Sveaskog tillhandahöll skördardata från avverkningsuppdrag inom studieområdet, som utfördes under en period från hösten 2015 fram till våren 2017. Den beräknade arealen för det insamlade åtgärderna blev 6226 ha, varav 1857 ha från slutavverkningar (Tabell 1) och 4369 ha från gallringar (Tabell 2).

För att kunna använda skördardata från gallringsåtgärder, behövs en prognos av kvarvarande bestånd efter utförd åtgärd. Skogforsk har utvecklat ett verktyg som kan göra detta, inom projekt för gallringsuppföljning (ref). I materialet ingår områden som gallrats före flygfotograferingen (11-12 april 2016), där endast prognosen av kvarvarande bestånd använts för att beskriva skogen, men även områden som gallrats efter datumen för flygfotona har använts, där läggs prognosen för kvarvarande bestånd ihop med en skoglig beskrivning av uttaget.

Tabell 1. Skördardata från slutavverkning, 1716 beräkningsytor

	Volym (m3sk/ha)	Grundyta (m2/ha)	HGV (m)	DGV (mm)	Antal Stammar	Tall	Gran	Lov
medel	306.2	29.4	23.5	306.9	555	0.27	0.68	0.05
min	104.5	13	14.9	183	211	0	0	0
max	773.7	61.1	31.9	457	1605	1	1	0.98
SD	102.5	7.8	2.8	38.3	162	0.25	0.25	0.1

Tabell 2. Skördardata från gallring, totalt 4923 beräkningsytor

	Volym (m3sk/ha)	Grundyta (m2/ha)	HGV (m)	DGV (mm)	Antal Stammar	Tall	Gran	Lov
medel	142.3	18.7	16.3	198.5	869	0.46	0.41	0.13
min	44	12.1	9.4	116	266	0	0	0
max	327.1	29.4	25.5	370	1862	1	1	0.98
SD	42.5	2.7	2.8	39.7	281	0.34	0.29	0.17

## Utvärderingsdata

Som utvärderingsdata användes den företagstaxering som Sveaskog genomförde i studieområdet 2017. Den bestod av 840 provytor insamlade i 89 olika bestånd, 6-10 provytor per bestånd. Datainsamlingen gjordes enligt IPAK-modellen. Provytedata bearbetades i Heureka och sammanställdes beståndsvis för utvärdering mot skattningarna (Tabell 3).



Tabell 3. Egenskaper för 89 utvärderingsbestånd inventerade av Sveaskog

	Volym (m <sup>3</sup> sk/ha)	Grundyta (m <sup>2</sup> /ha)	HGV (m)	DGV (cm)
medel	167.3	19.89	14.71	18.59
min	0	0	0	0
max	823.9	76.94	25.17	33.57
SD	123.6	11.6	6.6	8.81

## Metod

### Introduktion

Den främsta utmaningen inom projektet gäller användningen av skördardata som fältreferens istället för fältmätta provytor. Metodutvecklingen fokuserade på hur dessa nya indata kan nyttjas och ge svar på frågor som: Hur mycket skördardata som behövs; storlek på beräkningsytor, aktualitet på skördardata, geografiskt avstånd mellan referensdata och skattning samt nyttan med att använda kompletterande indata (stöd till skördardata) baserat på markmodellen.

Skördardata samlas in från tiden direkt efter flygbilden är registrerad för slutavverkningar. För gallringar där den kvarstående skogen beskrivs tilläts även skördardata från den tidigare vegetationssäsongen och fram till registreringstidpunkten för flygbilderna. Sedan delas utförda avverkningar in i små (0,1-1 hektar) beräkningsytor baserat på den skogliga beskrivningen i skördardata.

Den nya markmodellen används tillsammans med flygbilder för att producera motsvarande information om skogens tillstånd som med laserskanning, dvs. 3D data med noggrann mätning av framförallt trädhöjd. 3D data beräknas genom stereomatchning av nationellt tillgängliga flygbilder, exponerade innan avverkning, med fotogrammetriprogrammet SURE.

Karteringen av skogliga data från flygbildernas 3D-information genomfördes med areametoden (Næsset et al. 2004), dvs en etablerad standard även kallad imputering. Även en annan metod, Deep Learning testades. Bägge metoderna redovisas separat nedan. Metoderna innebär i korthet att sambandet mellan flygbildernas 3D-data och skördarmätningarna av skogliga parametrar modelleras matematiskt med hjälp data från beräkningsytorna och dessa modeller används därefter för att prediktera de skogliga målparametrarna i alla områden med flygbildstäckning. Resultatet blir yttäckande skattningar av de skogliga parametrarna.

De framtagna skattningarna analyserades och utvärderades mot olika oberoende material. Med hjälp av skördaravverkade objekt kan noggrannheten i skattningarna utvärderas, dels generellt och dels avseende skillnader mellan

olika skogstyper. Den objektiva företagstaxering som Sveaskog genomförde var ett mycket lämpligt utvärderingsmaterial över området.

## Imputering

Vi har valt att använda termen ”imputering” för tekniken att söka ett antal närbelägna avverkade beräkningsytor med liknande fjärranalysmetriker och överföra en skoglig beskrivning från dessa. Metoden för imputering som användes kallas kMSN och är en utveckling av Moeur & Stages (1995) ”Most Similar Neighbour”-metod, där ett antal ( $k$ ) av de mest liknande referensytorna (grannarna) väljs ut för varje yta som skall skattas. Medelvärdena av skattningsvariablerna från dessa ”grannar” överförs till prognosytan. Imputering kräver dock en omfattande referensdatabas. Detta eftersom metoden inte kan extrapolera skattningar utan endast väljer ur det tillgängliga referensmaterialet och beräknar ett viktat medelvärde av skogliga parametrar från detta urval.

För att skatta skogliga parametrar för segmenten användes kodbiblioteket ”yaImpute” (Crookston & Finley 2007) för programpaketet ”R” (Anon. 2016) som är fritt tillgängligt. ”yaImpute” utför imputering på multivariata data, vilket innebär att hela den skogliga beskrivningen kan skattas med en och samma funktion.

## Deep Learning

Det finns idag en mångfald av komplexa problem som har lösts med hjälp av självlärande algoritmer utvecklade inom forskningsfältet Machine Learning (ML) och artificiell intelligens (Goodfellow et al., 2016). Inom ML har speciellt nya metoder baserade på neurala nätverk fungerat mycket väl för att med hjälp av stora mängder data modellera mycket svårstuderade beroende i mätningar. Neurala nätverk är inget nytt forskningsfält, det har snarare fått en renässans tack vare dagens kraftfulla processkapacitet som gjort det möjligt att använda djupa nätverk. Detta är grunden i deep learning, den snabbast växande ML-metoden, för vilket Google har släppt källkod, Tensor Flow (Abadi et al., 2015), tillgänglig för alla. En grund i ML-konceptet är att utnyttja stora mängder data för att automatiskt ”träna” en algoritm att bli en effektiv prediktor, istället för att vara låst till förhållandevis enkla matematiska modeller som inte säkert beskriver multivariata samband som är svåra att upptäcka manuellt. Geografisk kartering av stora skogsområden baserat på enkelt tillgängliga fjärranalysdata och skördardata från avverkningar som registreras rutinmässigt bör vara en tillämpning där ML-metoder är effektiva alternativ till dagens inventerings- och modellbaserade karteringsmetoder. I detta projektet användes ett feed-forward neuralt nätverk implementerat i Tensor Flow (via KerasLab) för en första utvärdering av metoden. Flera olika nätverk utvärderades, där vart och ett simultant skattade DGV, HGV, grundyta och volym från krontakshöjdsdata från de stereomatchade flygbilderna (för detta användes medelvärde och standardavvikelse för den 20:e, 60:e och 95:e höjpercentilen inom beräkningsytan, samt även medelvärde och standardavvikelse för typvärdet av höjden).

## Utvärdering

Framtagna modeller utvärderades dels med korsvalidering och dels med hjälp av ett oberoende datamaterial (kontrolltaxerade bestånd från Sveaskog). Genom att beräkna standardavvikelse (ekvation 1 & 2) erhöles mått på den genomsnittliga variationen i skattningarnas avvikelse från uppmätta värden. För att jämföra precisionen för olika varianter på skattningar användes absoluta och relativa medelfel (ekvation 3 & 4). Systematiska avvikelser för skattningar identifierades och kvantifieras i absoluta och relativa mått med hjälp av ekvation 5 & 6.

$$SD = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}} \quad [1]$$

$$SD\% = 100 * \frac{SD}{\bar{y}} \quad [2]$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_i - y_i)^2}{n}} \quad [3]$$

$$RMSE\% = 100 * \frac{RMSE}{\bar{y}} \quad [4]$$


$$Bias = \frac{\sum_{i=1}^n (x_i - y_i)}{n} \quad [5]$$

$$Bias\% = 100 * \frac{Bias}{\bar{y}} \quad [6]$$

I ekvationerna representerar  $n$  antalet prognosytor,  $x_i$  det skattade värdet för prognosyta  $i$ ,  $y_i$  det observerade värdet för prognosyta  $i$ ,  $\bar{x}$  medelvärdet av de skattade värdena och  $\bar{y}$  medelvärdet av de observerade värdena.

Korsvalidering genomförs med samma datamaterial som använts för att anpassa skattningsmodellerna med och ger en uppskattning av modellernas noggrannhet utan ytterligare datamaterial. Det utförs genom att en (eller flera) observationer undantas från datamaterialet, modellerna anpassas till det resterande datamaterialet och de anpassade modellerna används för att prediktera målparametrarna på de undantagna observationerna. Detta upprepas till dess att alla observationer har tilldelats predikterade värden, och modellernas skattningsnoggrannheter kan slutligen beräknas genom att jämföra verkliga med predikterade värden för alla observationer.

Utvärdering med ett oberoende datamaterial genomfördes genom att göra skattningar för segmenterade delar i 89 taxerade bestånd (Figur 2) inom försöksområdet och jämföra en arealviktad sammanställning av skattade värden för segmenten i varje bestånd med beståndsmedelvärden från taxering.



Figur 2. Ortofoto för en kontrolltaxerad avdelning från Sveaskog (avdelningsgräns i rött) med automatiskt genererade prediktionssegment (vitt) (© Lantmäteriet).

## Resultat

### Imputering


Under arbetet med att ta fram en modell för imputering av skogliga parametrar utfördes korsvalidering av olika modeller för jämförelse. Skattningar gjordes för över 6000 enskilda beräkningsytor och resultaten utvärderades mot den skogliga beskrivningen av beräkningsytan med ekvation 1-6. Utvärderingen av en modell som inkluderade både laser- och fotogrammetrimeretriker samt satellit- och geodata presenteras i Tabell 4.

Sambanden mellan volym och medelhöjd (Figur 3), och volym och grundyta (Figur 4) fångas bra med imputering, men fröträdsställningar är svårskattade (uppe till vänster i Figur 3). Genom att använda medelvärdesbildning fångas dock inte hela variationen i skogen.


För att skatta utvärderingsbestånden gjordes separata prognoser för delar (segment) av utvärderingsbestånden. Förhållandet mellan volym och grundytavägd medelhöjd (Hgv) kan ses i Figur 5, medan Figur 6 illustrerar sambanden mellan volym och grundyta.

Tabell 4. Resultat för korsvalidering av skattningar för enskilda beräkningsytor

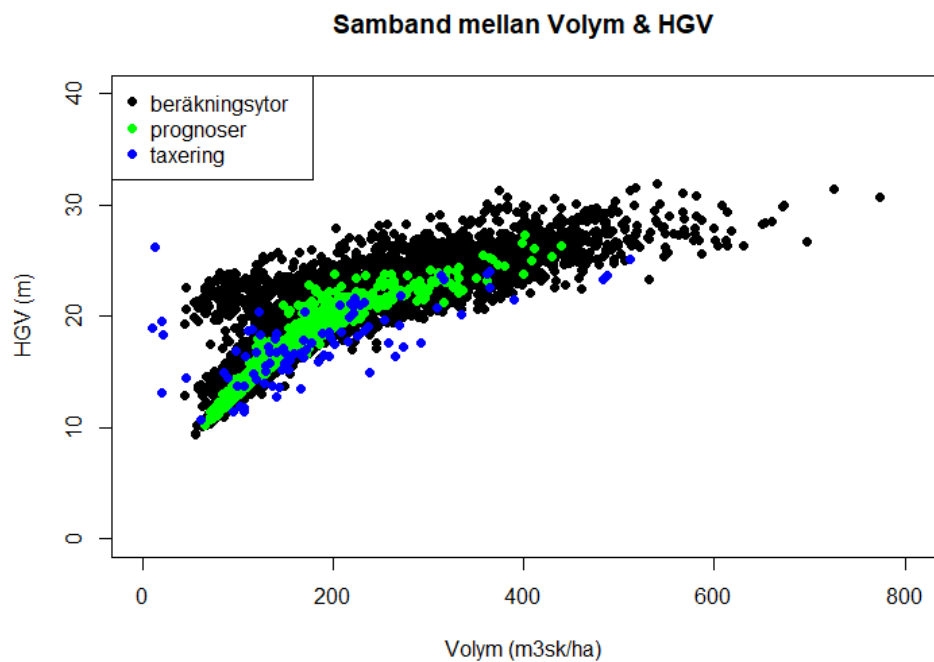
	Enhet	RMSE	RMSE%	Bias%
Volym	m <sup>3</sup> sk/ha	35.5	19.2	-0.3
Hgv	m	1.2	6.6	-0.1
Dgv	cm	2.5	11.2	-0.1
Grundyta	m <sup>2</sup> /ha	3.1	14.6	-0.1



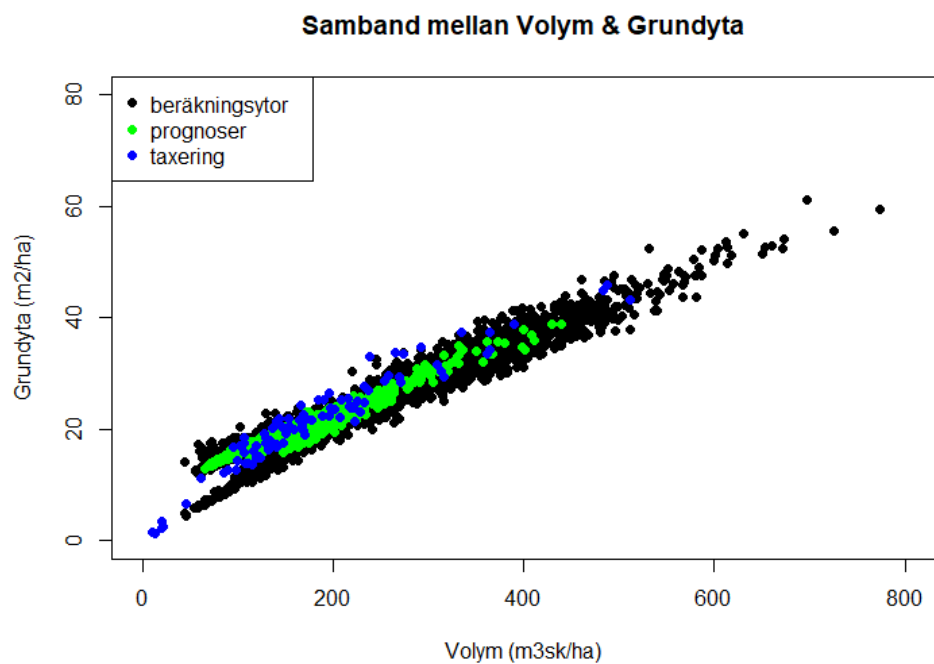
Figur 3. Samband mellan volym och grundtyvägd medelhöjd (Hgv) för beräkningsytor (svart) och prognoser för enskilda beräkningsytor baserade på medelvärdesbildning av 5 beräkningsytor (grön).



Figur 4. Samband mellan volym och grundyta för beräkningsytor (svart), skattningar för beräkningsytor (grön).



Figur 5. Samband mellan volym och Hgv för beräkningsstyr (svart), imputerad prognos för delar (segment) av utvärderingsbestånd (grön) samt taxeringsdata från utvärderingsbestånd (blå).



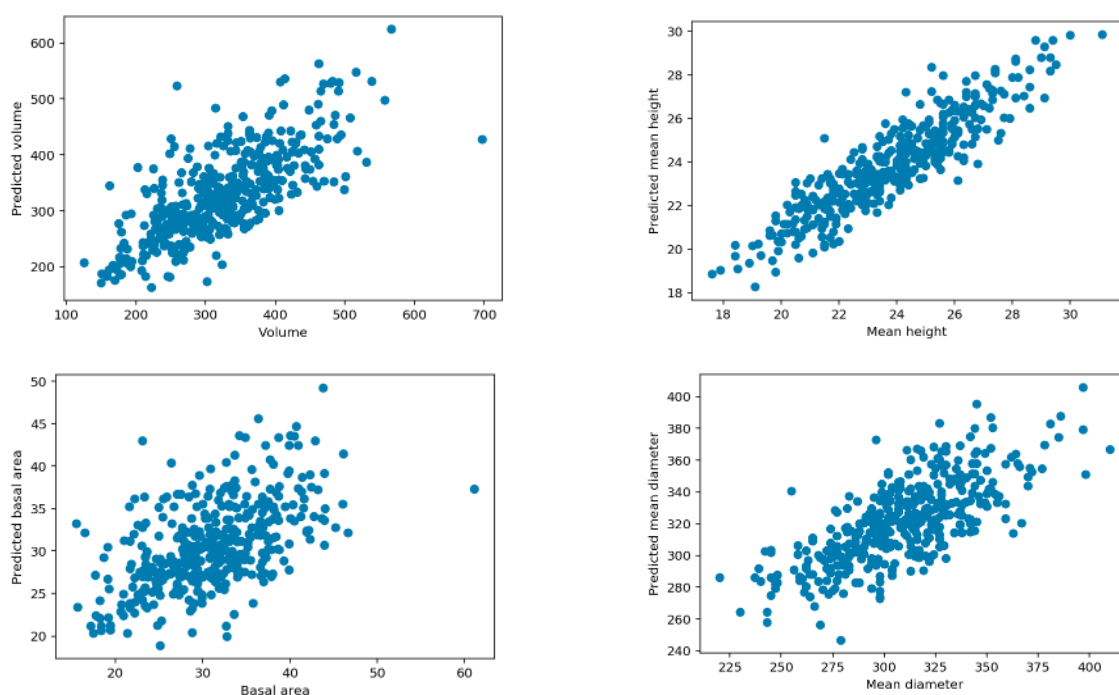
Figur 6. Samband mellan volym och grundyta för beräkningsstyr (svart), skattningar för delsegment av utvärderingsbestånd (grön) samt taxeringsdata från utvärderingsbestånd (blå).



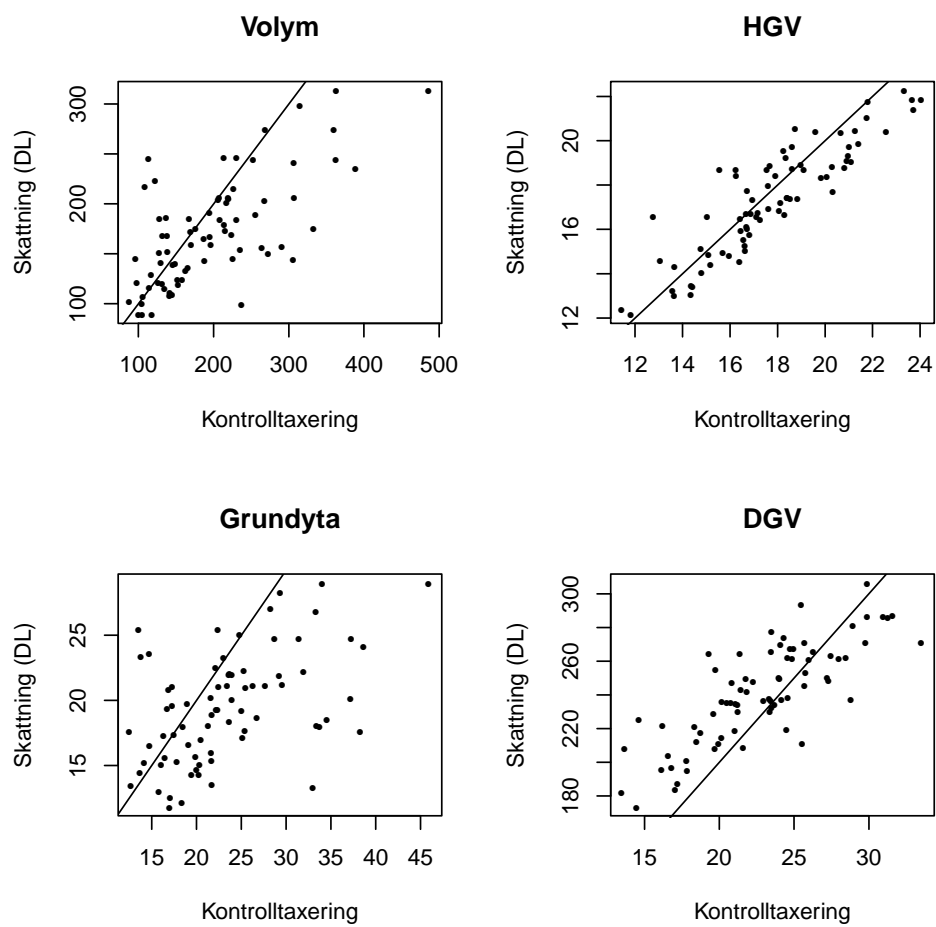
## Deep Learning

Ett flertal olika neurala nätverk utvecklades i Tensor Flow och utvärderades parallellt, genom att iterativt träna nätverket på 60% av det tillgängliga datamaterialet från skördaravverkningarna inom studieområdet, och utvärdera med resterande 40% (detta kan möjligen liknas vid en korsvalidering, men utförs som en grundläggande del av träningen av nätverket en grundläggande del av). Det bästa nätverket användes till sist för att prediktera de kontrolltaxerade avdelningarna från Sveaskog och från dessa prediktioner beräkna noggrannhetsmått (ekvationerna 3 – 6). Nätverk med djup mellan 2 och 8 provades och med 64 eller 128 noder. Det nätverk som fungerade bäst (Figur 7 och 8) består av tre lager och 64 noder, större och mer komplexa tenderade att bli överanpassade och leverera sämre skattningar.

Datamaterialet i denna studie var sannolikt för begränsat för att denna metod ska kunna prestera väl, men det behövs även betydligt mer utvecklingsarbete för att konstruera ett djupt neuralt nätverk som effektivt kan anpassas för denna tillämpning.



Figur 7. Resultat från korsvalidering med Deep Learning (DL).



Figur 8. Resultat från skattningar av utvärderingsbestånden med Deep Learning (DL).

## Diskussion och slutsatser

En förutsättning för att kunna använda skördardata som markreferens är kvalitetssäkrad kalibrering av skördarmätningen. Skördarförarna klavar in två träd/stockar per dag och oberoende revisorer kontrollerar skördarmätningen mot inklavade stockar. Koordinater för avverkade träd är också nödvändiga, idag är trädpositioner osäkra då endast skördarens position registreras, men ny teknik, främst inom kranstyrning ger högre precision för enskilda träd (Hauglin et al. 2017). Lämnade träd och naturvårdshänsyn är ett problem, men från version 3.1 av Stanford 2010 finns stöd för att dokumentera kvarlämnade träd och naturhänsynsåtgärder. Anpassning av användargränssnitt pågår hos maskintillverkare och ett fåtal testmaskiner är i drift idag.

De utvärderingsdata som användes från Sveaskog håller en hög kvalitet och fanns i stor kvantitet över studieområdet. Det gör att resultaten bör ha blivit ordentligt utvärderade även om metoderna alltid kan utvecklas. Ett speciellt problem med den areabaserade skattningsmetoden som används här är att den baseras på beräkningsytor som naturligtvis inte finns tillgängliga för områden som är mål för prediktering. Den segmentering som utnyttjas för att skapa prediktiva enheter följer inte nödvändigtvis de avdelningsgränser som användes för Sveaskogs kontrolltaxering. Konsekvensen av detta är att projektet redovisar resultat som sannolikt ser ut att vara sämre än de är i verkligheten, eftersom en okänd del av noggrannheten gått förlorad på grund av diskrepansen mellan avdelningsgränserna och skattningssegmenten.

Skördardata samlas rutinmässigt in för i stort sett alla avverkningar i hela landet, det produceras alltså löpande enorma mängder noggranna data över skogens tillstånd för helt andra ändamål än skoglig kartering. Detta, i kombination med stereomatchade flygbilder, som också produceras löpande för hela landet, är en enorm resurs för att beräkna rasterskattningar av skogliga parametrar med nationell täckning. Kostnaderna för data är små och möjligheterna för kontinuerliga uppdateringar av rasterskattningarna är stora. För detta ändamål är DL-metoder mycket lämpade, de kan utnyttja stora datamängder för att ersätta statistisk modellering med artificiell intelligens och de kan automatiskt uppdateras med nya data och producera nya rasterskattningar. I detta projektet utprovades en första DL-algoritm och visade klart att metoden fungerar, men betydande ytterligare utvecklingsarbete kommer att behövas för att ta fram en operativ metod.

Resultaten från korsvalideringen var lovande, att använda beräkningsytor som markreferens gav skattningar i klass med tidigare fotogrammetriska skattningar baserade på provytor från riksskogstaxeringen. Skattningarna gav heller inga några nämnvärda systematiska avvikelser. Skattningarna för segment av utvärderingsbestånden gav liknande samband, men lyckades inte fånga variationen i utvärderingsbestånden fullt ut, framförallt var några bestånd med mycket låg grundyta problematiska, då de låg utanför referensmaterialets spännvidd.

Utvärdering med hjälp av kontrolltaxerade avdelningar behöver utvecklas för att kunna ge rättvisande resultat. Metoden som användes i detta projekt är inte

optimal eftersom utvärderingen riskerar att ske på ytor som inte helt överensstämmer. Segmentering är nödvändig för att skapa prediktionsenheter som motsvarar beräkningsytorna från skördardata, men segmenteringen bör sannolikt genomföras med avdelningsgränserna som tvingande gränser istället för den arealviktningen som användes i detta projekt.

Produktionen av data från skördare och olika fjärranalysmetoder är mycket stor idag och kommer sannolikt att öka än mer i framtiden. Det kommer att behövas nya analysmetoder för att dra full nytta av detta. Deep Learning, och andra ML/AI-metoder, har visat sig mycket kraftfulla i andra tillämpningar med liknande mängd data och komplexa frågeställningar och de är sannolikt vägen framåt även för de tillämpningar som detta projekt inriktats mot. Även betydligt mer intrikata egenskaper, som virkesegenskaper och skadefrekvens, bör vara möjliga att kartera med hjälp av Deep Learning och stora mängder träningsdata för att lyckas få de neurala nätverken att fånga dessa komplexa samband.

## Referenser

- Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., ... Zheng, X. 2015. TensorFlow: Large-scale machine learning on heterogeneous systems. Retrieved from <https://www.tensorflow.org/> (Software available from tensorflow.org)
- Anon. 2016. R Core Team. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.
- Arlinger, J., Nordström, M. & Möller, J.J. 2012. StanForD 2010. Modern kommunikation med skogsmaskiner. – StanForD 2010. – Modern communication with forest machines. Arbetsrapport 784. Skogforsk. 16 s.
- Bhuiyan, N. 2015. Pers medd. hprYield verktyg för stratifiering och beräkning av skogliga parametrar med hjälp av skördardata.
- Bhuiyan, N., Möller J.J. & Arlinger, J. 2018. hprYield – beräkningsmodul för generering av geografiskt uppdelade nyckeltal baserat på skördardata. Arbetsrapport XX, Skogforsk. XX s. Manuskript under publicering 2018.
- Crookston, N.L. & Finley, A.O. 2007. yaImpute: An R Package for k-NN Imputation. *Journal of Statistical Software*. 23(10): 1–16.
- Goodfellow, I., Bengio, Y., & Courville, A. 2016. Deep learning. MIT Press.
- Hannrup, B. Bhuiyan, N. & Möller, J.J. 2015. Rikstäckande utvärdering av ett system för automatiserad gallringsuppföljning. Arbetsrapport 857, Skogforsk.
- Hauglin, M., Hofstad Hansen, E., Naesset, E., Busterud, B.E., Omholt Gjevestad, J.G. & Gobakken, T. 2017. Accurate single-tree positions from a harvester: a test of two global satellite-based positioning systems. *Scandinavian Journal of Forest Research*, 32:8, p. 774–781.
- Holmgren, J., Barth, A., Larsson, H., & Olsson, H. 2012. Prediction of stem attributes by combining airborne laser scanning and measurements from harvesters. *Silva Fennica*, 46(2), 227 - 239.
- Lantmäteriet. 2018. Produktbeskrivning: Ytmodell från flygbilder och Ytmodell från flygbilder IRF. Dokumentversion 1.0 (2016-10-25). Lantmäteriet, Gävle. ([http://www.lantmateriet.se/globalassets/kartor-och-geografisk-information/hojddata/produktbeskrivningar/ytmodell\\_fran\\_flygbild2.pdf](http://www.lantmateriet.se/globalassets/kartor-och-geografisk-information/hojddata/produktbeskrivningar/ytmodell_fran_flygbild2.pdf)).
- Leach J., Lidberg W., Kuglerová L., Kuglerova L., Peralta Tapia A., Ågren A. & Laudon H. 2017. Evaluating topography-based predictions of shallow lateral groundwater discharge zones for a boreal lake-stream system. *Water Resources Research*, 53 (7), pp.5420-5437.

Moeur, M. & Stage, A.R. 1995. Most Similar Neighbor: An Improved Sampling Inference Procedure for Natural Resource Planning. *Forest Science*, 41(2), pp 337–359.

Möller, J. J, Arlinger, J., Barth, A., Bhuiyan, N., & Hannrup, B. 2011. Ett system för beräkning och återföring av skördarbaserad information till skogliga register och planeringssystem. Arbetsrapport 756, Skogforsk.

Möller, J.J., Bhuiyan, N. & Hannrup, B. 2015. Utveckling och test av beslutsstöd vid automatiserad gallringsuppföljning. Uppsala: Skogforsk. (Arbetsrapport 862-2015).

Möller, J.J., Söderberg, J., Arlinger, J., Eriksson, I., Bhuiyan, N. & Willén, E. 2017. Utbytesprognoser baserat på skogliga data och skördarinformation – Modell och systembeskrivning för ”Skapande av stambanker och imputerad utbytesprognos baserat på skogs- och skördardata på objektsnivå”. Uppsala: Skogforsk. (Arbetsrapport 961-2017).

Næsset, E., Gobakken, T., Holmgren, J., Hyypä, H., Hyypä, J., Maltamo, M., . . . Soderman, U. 2004. Laser scanning of forest resources: The Nordic experience. *Scandinavian Journal of Forest Research*, 19(6), 482-499.

Pennock, D.J., Zebarth, B.J., & De Jong, E. 1987. Landform classification and soil distribution in hummocky terrain, Saskatchewan, Canada. *Geoderma* 40(3): 297 – 315.

Rothermel, M., Wenzel, K., Fritsch, D., & Haala, N. 2012. SURE - photogrammetric surface reconstruction from imagery. In *Lc3d workshop* (p. 1-9). Berlin, Germany.

Söderberg, J. 2015. A method for using harvester data in airborne laser prediction of forest variables in mature coniferous stands, Arbetsrapport 443. Sveriges Lantbruksuniversitet, Inst. för skoglig resurshushållning, 901 83 Umeå.

Sørensen, R., Zinko, U., Seibert, J. 2006. On the calculation of the topographic wetness index: evaluation of different methods based on field observations. *Hydrology and Earth System Sciences*. 10: 101–112.