



AI-stödd travmätning baserad på travbilder, vikt och skördardata

Lars Björklund, Sven Jägbrant, Tanja Keisu & Peter Lenaers

Innehållsförteckning

1	SAMMANFATTNING	2
2	INLEDNING	2
2.1	Bakgrund	2
2.2	Inledande studier där AI använts	3
2.2.1	<i>Traves volym via maskininlärning - Mittuniversitetets studie</i>	<i>3</i>
2.2.2	<i>Automatisk bestämning av travhöjd och vedlängd</i>	<i>4</i>
2.2.3	<i>Kompletterande studie på travar med kran</i>	<i>5</i>
2.3	Syfte och krav	5
3	MATERIAL OCH METODER.....	6
3.1	Data	6
3.1.1	<i>Beteckningar på mått och variabler som används i studien</i>	<i>6</i>
3.1.2	<i>Bilder och data från travmätning via bildmätning (IRIS-data).....</i>	<i>6</i>
3.1.3	<i>Skördardata.....</i>	<i>7</i>
3.1.4	<i>Matchning av IRIS-data och skördardata.....</i>	<i>8</i>
3.1.5	<i>Stockmätta stickprovstravar för utvärdering av modellen.....</i>	<i>10</i>
3.2	Modellutveckling - Identifiering av förklarande variabler	10
4	RESULTAT	11
4.1	Val av variabler till modellen	11
4.2	Utvärdering av modellens mätningens kvalitet per sortiment	13
4.3	Systematisk avvikelse per månad	15
5	DISKUSSION OCH SLUTSATSER.....	15
5.1	Den framtagna AI-modellen	15
5.2	Förbättrat mätresultat med AI-modellen	16
5.3	Implementering av modellen	16
5.4	Idéer för kommande studier och utökad implementering av metoden	17
6	LITTERATURFÖRTECKNING	18

1 Sammanfattning

Att kunna automatisera travmätningen av virke i Sverige är ett utvecklingsmål som flera aktörer idag jobbar mot, men med lite olika tekniker och inriktningar. I denna rapport presenteras ett sätt att bestämma travars volym utifrån bilder på travar, data från skördare samt viktdata - med hjälp av maskininlärning. Resultatet visar att den systematiska avvikelserna med denna metodik ligger på ungefär samma nivå som vid fjärrmätning (travmätning i bild/bildmätning) samt att spridningen för enskild trave är lägre. Resultatet visar att metodiken kan tillämpas för att automatisera och förbättra travmätningen.

2 Inledning

2.1 Bakgrund


Inom virkesmätningen efterfrågas metoder för att automatiskt bestämma volymen på virke som är lastat på fordon. Mätningen kan utgå från travmätning eller vägning.

Travmätning

Traves volym bestäms som produkten av traves mått (travhöjd, vedlängd, bankbredd/travlängd) och vedvolymprocent (figur 1). Vedvolymprocenten är andelen ved av den tänkta lådans volym. Historiskt har denna mätning gjorts manuellt när fordonet stått vid en mätbrygga.

BB = bankbredd
 BB1 = övre bankbredd
 BB2 = nedre bankbredd

VL = vedlängd
 H = traves höjd



Figur 1. Vid travmätning bestäms traves volym som produkten av vedlängd, travhöjd, bankbredd och vedvolymprocent.

Travmätning i bilder (fjärrmätning)

På senare år har bildriggar och fjärrmätning ersatt stora delar av den mätning som tidigare gjordes lokalt på respektive mätplats. Det har också utvecklats utrustningar för hel- eller delautomatisk travmätning. Vid travmätning med hjälp av bildmätning tas minst tre bilder per trave (figur 2). En sidobild i vilken mätning av travhöjd och vedlängd utförs, och två gavelbilder vilka nyttjas för bedömning av vedvolymprocent och virkeskvalitet. I gavelbilderna bedöms även stakarnas lutning för att avgöra om registervärdet för

bankbredd ska justeras. Mätningen registreras i Biometrias IT-system IRIS. Mätresultatet benämns därför IRIS-data i denna rapport.



Figur 2. Vid bildmätning tas minst tre bilder per trave, sidobild till vänster och gavelbilder i mitten och till höger. I projektet användes sidobilden och en AI-funktion för att automatiskt bestämma travhöjd och vedlängd. Arean av respektive rektangel användes för att fördela lastens vikt på enskilda travar.

Vägning

Fordonsvåg finns idag vid de flesta mätplatser. Vid vägning används omvandlingstal från vikt till volym. Omvandlingstalen kan vara kopplade till faktorer som datum, trädslag, stockarnas diameter etc. Undersökningar så tidigt som på 1950-talet visade att vägning var särskilt lämpat för lövmassaved. Från början av 2000-talet och fram till att fjärrmätningen infördes tillämpades ”52-metoden” (vägning kombinerat med datum och bedömda faktorer) för en stor del av massaveden i norra Sverige (Ölund & Selin, 1999).

AI öppnar nya möjligheter

Med artificiell intelligens (AI) öppnas nya möjligheter att analysera stora dataset med många variabler, där även bilder kan ingå. Genom AI-baserade modeller för bestämning av traves volym kan information från skördardata, travmätning och vikt användas.

Neurala nätverk är en specifik AI-tillämpning inom maskinlärning som innefattar ett antal olika typer av modeller. Principen för hur modellerna fungerar drar inspiration från hur den mänskliga hjärnan fungerar, d.v.s. att neuroner interagerar med varandra och för relevant information vidare i kedjan. Gemensamt för modellerna är att de byggs upp av ett antal lager, som vart och ett innehåller ett visst antal ”neuroner” (noder), där varje lager identifierar vissa mönster i data. Dessa mönster är gömda i nätverket vilket betyder att det kan vara svårt att tolka inverkan av en viss variabel. Det övergripande syftet med neurala nätverk är, precis som andra maskininlärningsmetoder, att effektivt göra prediktionsmodeller baserade på träningsdata.

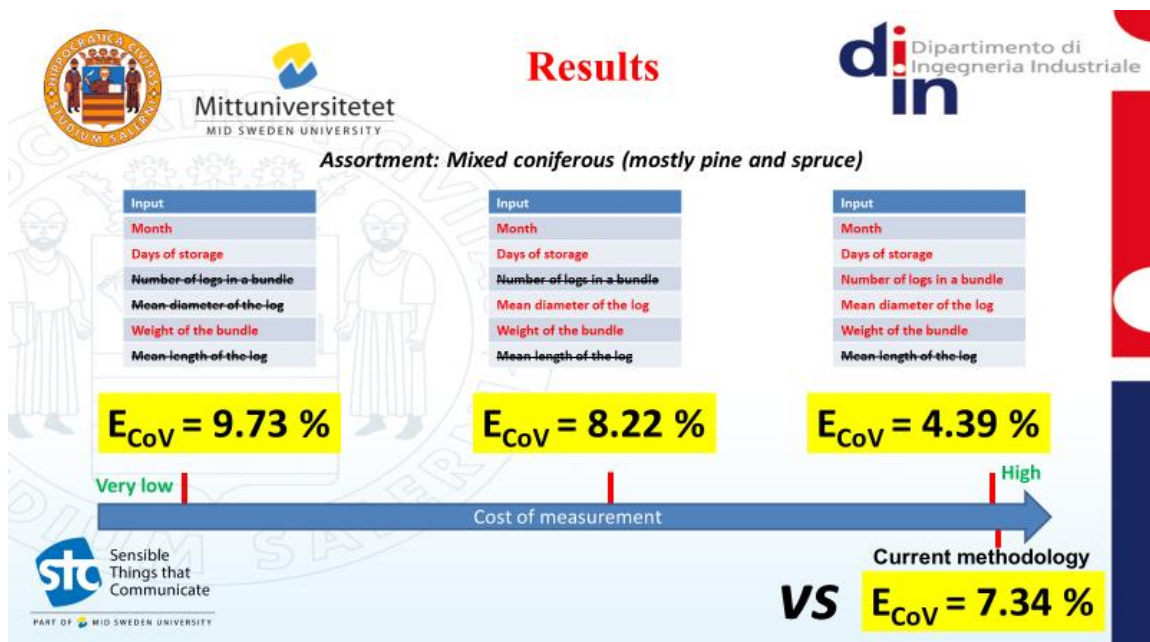
2.2 Inledande studier där AI använts

2.2.1 Traves volym via maskininlärning - Mittuniversitetets studie

Under sommaren 2018 gjorde Mittuniversitetet en studie rörande automatisk bestämning av traves volym baserad på maskininlärning (Carratú, o.a., 2019). I processen användes variabler som sortiment, datum, medeldiameter och traves vikt. Travvikten skattades utifrån fordonets lastvikt och travarnas travmätta volymer. I studien ingick ca 17 000

stickprovstravar av sortimenten barr-, gran-, löv- och contortamassaved, inmätta 2015–2018. Modellen tränades mot den stockmätta volymen.

Resultaten var mycket lovande (figur 3), även om det fanns en del oklarheter i hur data använts. Eftersom en del information som modellen baserades på hämtades från stockmätningen (antal stockar i traven, stockarnas medeldiameter), skulle den inte kunna användas i praktiskt bruk för automatisk travmätning.



Figur 3. Exempel på resultat från Mittuniversitetets studie där maskininlärning användes för att bestämma traves volym (från Carratú m fl. 2019).

2.2.2 Automatisk bestämning av travhöjd och vedlängd

Under hösten 2018 genomförde SDC ett arbete tillsammans med Forefront där maskininlärning användes för att bestämma travhöjd och vedlängd (rektangeln) i bilder på virkestravar (Finnström, Jägbrant, & Lenaers, 2018). I studien uteslöts krantravar och delade travar. Av tillgängliga bilder valdes slumpmässigt 147 000 bilder för träningsdatasetet och 3000 bilder för valideringsdatasetet. Alla bilder härrörde från bildriggar med fast avstånd till virkestravarna (s.k. "Biometriariggar"). För en modellutvärdering (testdata) användes ca 2500 bilder på stockmätta stickprovstravar där vedlängden var noggrant bestämd.

Modellen uppfyllde noggrannhetskraven för både vedlängd och travhöjd. Det systematiska felet för längden i förhållande till stickprovsdata var i samma storleksordning som virkesmätarnas fel, och standardavvikelsen var lägre. Bestämningen av travhöjd avvek väldigt lite från mätarnas bedömning. Sammantaget hade modellen samma eller lite bättre precision än virkesmätarna, samt gav en mer enhetlig bedömning av travmåten. Denna metod för mätning av travmått (vedlängd och travhöjd) godkändes sedan av VMK.

2.2.3 Kompletterande studie på travar med kran

I det nu aktuella projektet var tanken att rektanglarna skulle vara bas för att fördela lastens vikt på travarna (oftast tre travar). Om en av fordonets travar saknar rektangel måste då hela fordonet strykas från analyserna, vilket skulle innebära en kraftfull begränsning av datamaterialet. Att kunna beräkna rektangelmått även på krantravar innebär också att det färdiga systemet kan få en mycket bredare tillämpning jämfört med att bara kunna användas på fordon utan kran.

Därför beslöts att göra en test av hur väl den tidigare utvecklade AI-modellen fungerade på krantravar. Eftersom krantraven vid ”vanlig” virkesmätning mäts med sämre noggrannhet jämfört med andra travar kan det accepteras att även ”rektangelbestämningen” får något lägre noggrannhet jämfört med travar utan kran.

Resultat – även krantravar kunde användas

Den i det tidigare projektet utvecklade modellen för att skatta/bestämma rektangelns mått tillämpades på alla tillgängliga bilder (400 104 bilder). Av dessa var 77 786 ”kranbilder” och 322 318 ”icke kranbilder”. I genomsnitt gav modellen 1,57 %-enheter för hög travhöjd i förhållande till travens andel av bildhöjden på kranbilder, vilket motsvarar cirka 10 cm. Med detta som underlag beslutades att använda den tidigare utvecklade modellen även för ”kranbilder” men att då justera (minska) höjdmåttet med 1,57 %-enheter av travens höjd i förhållande till bildhöjden. Analysen visade något större spridning för krantravar än övriga travar vad gäller höjdmåttet, vilket var förväntat men acceptabelt. Denna utökning av metoden för automatisk bestämning av travmått även för krantravar godkändes av VMK hösten 2019 (Jägbrant, 2019).

Denna AI-analys (bildanalys av sidobilden) används i studien till två saker:

1. Bestämning av travhöjd och vedlängd för varje trave.
2. Fördelning av lastvikt till enskild traves vikt. Lastvikten fördelades proportionellt i förhållande till rektanglarnas area.

Metoden för att automatiskt mäta travens höjd och vedlängd (enligt ovan) implementerades i IRIS för att i skarp drift stödja virkesmätarna under december 2019, och fick då namnet AIDA.

2.3 Syfte och krav


Syftet med detta projektet var att utveckla en metod för bestämning av bruttovolymen för virkestravar lastade på lastbil genom en AI-modell som baseras på tillgängliga produktionsdata från skördare, lastens vikt vid mottagningskontroll och resultat på traves mått från automatisk bildanalys.

AI-modellen utvärderades gentemot rådande krav- och målnivåer på mätningens kvalitet för Biometria. Detta resultat kan användas som beslutsunderlag för att bestämma om och hur modellen ska tas vidare till en produktionslösning.

3 Material och metoder

3.1 Data

De data som använts i studien härrör från två primära källor; bilder på travar från biometriarigggar + data kopplat till bilderna samt skördardata (se figur 4). Skördardata skapas i och med att träden avverkas och stockarna mäts av skördaren, vilket sedan kompletteras med metadata från skördare. Bilderna på travarna uppkommer när lastbilar kör in virket från avlägget i skogen in till industri/terminal där travarna mäts in med hjälp av de kamerarigggar som tar kort på enskilda travar. Mätning av volymer hos dessa travar utförs sedan vid någon av de tre fjärrmätningssentraler som Biometria har runt om i landet.



Figur 4. Sammanfattande beskrivning av de grunddata som användes i studien.

3.1.1 Beteckningar på mått och variabler som används i studien

De beteckningar som används baseras på det utkast till formelsamling för VIOL 3 som finns (Strömgren & Björklund, 2019). Några av grundprinciperna är:

- Stor bokstav för grundbegrepp som längd (L), höjd (H), volym (V), massa/vikt (M) etc.
- Små och nedsänkta bokstäver eller text som förtydligar vilken längd etc. som avses.

3.1.2 Bilder och data från travmätning via bildmätning (IRIS-data)

Utsökning av fordon/leveranser/travar

Initialt utsöktes alla bilder och IRIS-data för tvåårsperioden, april 2017 – april 2019. Totalt ca 772 000 travar. För att ingå i studien krävdes att:

- Det var tre travar på fordonet
- Alla tre travarna på fordonet tillhörde samma leverans (virkesorder) och sortiment, dvs ingen samlast eller delade travar
- Lastvikten var registrerad

Därutöver ströks leveranser med orimliga lastvikter eller travmått, samt sortiment med färre än 500 travar (sortimentslista, se figur 5). Sortiment ”509” och ”500” sammanfogades, samt även sortiment ”102” och ”152”. Efter dessa avgränsningar återstod 411 833 travar. I projektet användes data från travmätning/bildmätning enligt tabell 1.

Tabell 1. Variabler som härrörde från IRIS-data.

Variabel	Beteckning	Förklaring / kommentar	Leverans	Trave
Redovisningsnummer	RNR	Mätningens identitet	X	
Virkesorder	VO	Avverkningens identitet via virkesorder sammankopplas med skördardata	X	
Sortiment	SS	Text barrmassaved, granmassaved, gransågtimmer etc., se figur 4	X	
Leveransdatum	LEV _{dag}	Datum när virket levererats till mottagaren. Kan vara någon dag före mätdatum	X	
Lastvikt	M _{last}	Vikt för travarna på fordonet	X	
Travevikt	M _{trave}	Lastvikt fördelad på enskild trave m.h.a. ”AI-rektangeln”		X
Krantrave		Anger om fordonet har kran eller inte.	X	X
Traves höjd	H _{trave-AI}	Resultat från AI-analys		X
Traves vedlängd	L _{ved-AI}	Resultat från AI-analys		X
Bankbredd	L _{bb}	Registeruppgift för dragbil respektive släp		X
Traves volym	V _{trave}	Bildmätarnas volymbestämning.		X
Travens position	POS _{trave}	Travens position på fordonet.		X

3.1.3 Skördardata

I skördarens produktionsrapportering lagras detaljerad information om varje enskild upparbetad stock (hpr-fil) och stam (stm-fil). Varje stock får en unik identitet så att produktionen från flera maskiner på samma objekt ska gå att rapportera med bibehållen möjlighet att spåra varje stock till en viss stam och maskin.

De variabler som användes för att utveckla en AI-modell listas i tabell 2. Efter rensning för felaktiga data omfattade skördardata information om stockar från 49,5 miljoner stammar.


Tabell 2. Variabler som härrörde från skördardata. Vissa av dem kom inte med i den modell som utvecklades, men omnämns i diskussionen.

Variabel	Beteckning	Förklaring / kommentar
Virkesorder	VO	Avverkningens identitet. Via virkesorder sammankopplas skördardata med data från bildmätningen (IRIS-data)
Latitud	LAT	Avverkningens position
Longitud	LONG	Avverkningens position
Geografiskt ursprung	XY _{grid}	Geografiskt ursprung, ruta baserad på latitud och longitud, se figur 5
Avverknings-tidpunkt	AVV _{dag}	Datum när skördarfilen skapades (sändes in)
Startdatum	AVV _{start}	Datum när första skördarfil på virkesordern skapades
Slutdatum	AVV _{slut}	Datum när sista skördarfil på virkesordern skapades

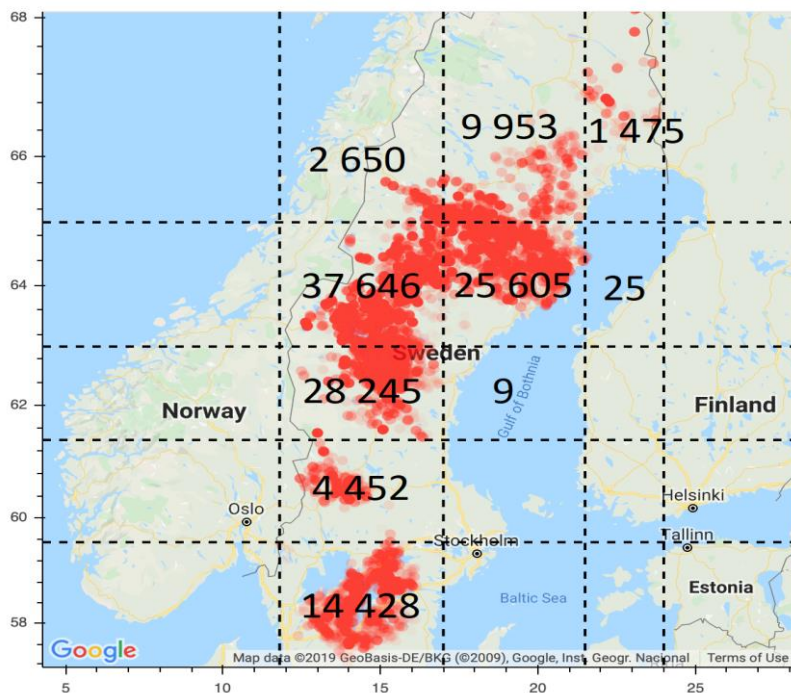
Avverknings-månad	AVV _{månad}	Månad för medeltal av start- och slutdatum
Sortiment	SS	Stockvariabel. Sortiment kan innehålls flera trädslag, ex.vis barrmassaved som innehåller tall och gran
Lagringstid	LAGR _{tid}	Om $LEV_{dag} > AVV_{slut}$: LAGR _{tid} = Antal dagar mellan snittet av AVV_{start} / AVV_{slut} och LEV_{dag} Om $LEV_{dag} < AVV_{slut}$: LAGR _{tid} = hälften av antal dagar mellan AVV_{start} och LEV_{dag}
Parti		Kombination virkesorder/sortiment
Trädslag	TRSL _{skördare}	Stamvariabel. I stamdatafilen åsätts varje stam sitt biologiska trädslag. Via ”trädslag” kan ett sortiments trädslagsblandning beräknas
Medelstock-diameter	D _{to-skördare}	Stockdatabasen innehåller ett antal diametrar (se figur 8). Av dessa valdes toppdiameter på bark baserat på att den hade minst antal saknade värden
Medelstock-längd	L _{ved-skördare}	Medeltal per sortiment

3.1.4 Matchning av IRIS-data och skördardata

Data från travmätning (IRIS-data) och skördardata sammanfogades baserat på virkesordernummer och sortiment. Detta resulterade i ett dataset där totalt 124 488 travar kunde ges information om resultat från skördardata. Fördelning på sortiment framgår av figur 5. I modellutvecklingen användes traves geografiska ursprung genom att ange vilken ”geografisk ruta” den tillhörde utifrån avverkningens position (figur 6). Travar inom två geografiska rutor med enbart 9 respektive 25 travar ströks ur analysen. Flera anledningar bidrog till att endast 124 488 av 411 833 travar kunde matchas med skördardata. I vissa fall saknades skördarfiler helt (t.ex. för leveransvirke), i andra fall var skördarfilerna inte kompletta, i några fall var filformatet så gammalt att det inte gick att konvertera dem. Slutligen handlade det i en del fall om virke som kom från terminal eller liknande och då inte kunde kopplas till en avverkning.




Figur 5. Antal travar per sortiment (VIOL-kod inom parentes) som kunde användas i AI-modellen.



Figur 6. Geografiskt ursprung för avverkningar samt den rutindelning som användes i modellutvecklingen. Antalet avverkningar i respektive ruta framgår av siffrorna i rutan. Rutor med 9 respektive 25 avverkningar uteslöts i analysen.

3.1.5 Stockmätta stickprovstravar för utvärdering av modellen

För utvärdering av modellen användes travens bruttovolym enligt stockmätning som referensvärde ($V_{\text{stock.mät}}$). Detta dataset baserades på stockmätta stickprovstravar inom mellersta och norra Sverige. Sydsveriges kontrolltravar ingick inte. Av de 124 488 travar där modellen kunde matcha IRIS-data och skördardata och bestämma en volym, så var det 1264 som hade stockmätts och det därmed fanns ett referensvärde (för travens volym) att utvärdera mot (figur 7).



Figur 7. Antal stockmätta travar som kunde matchas mot en predikterad volym från modellen uppdelat på sortiment. Sortiment med färre än 40 travar är bortplockade.

3.2 Modellutveckling - Identifiering av förklarande variabler

Ett neuralt nätverk tränades för att minimera skillnaden mellan virkesmätarens bedömning av volymen på travar och modellens prediktioner. När modellen tillämpas måste data ha samma variabler som modellen tränades på. Om nya data är helt utanför träningsdata kan man inte lita på de resultat modellen ger.

Modellen tränades mot virkesmätarnas volymbestämmning på de 124 488 travar där IRIS-data och skördardata kunde matchas (figur 5). Modellutvecklingen inleddes med att identifiera vilka variabler som borde vara med i modellen utifrån korrelationsanalyser. Därefter testades olika modeller med olika parameterinställningar för att ta fram bästa möjliga modell.

Beräkning av standardavvikelse och systematisk avvikelse för utvärdering av modellen

Standardavvikelsen beräknades som standardavvikelse för volymavvikelsen i förhållande till medeltraven – dvs en variationskoefficient. Den systematiska avvikelsen beräknades som summan av avvikelsen i volym per trave i förhållande till den totala stockmätta volymen för önskad aggregering.

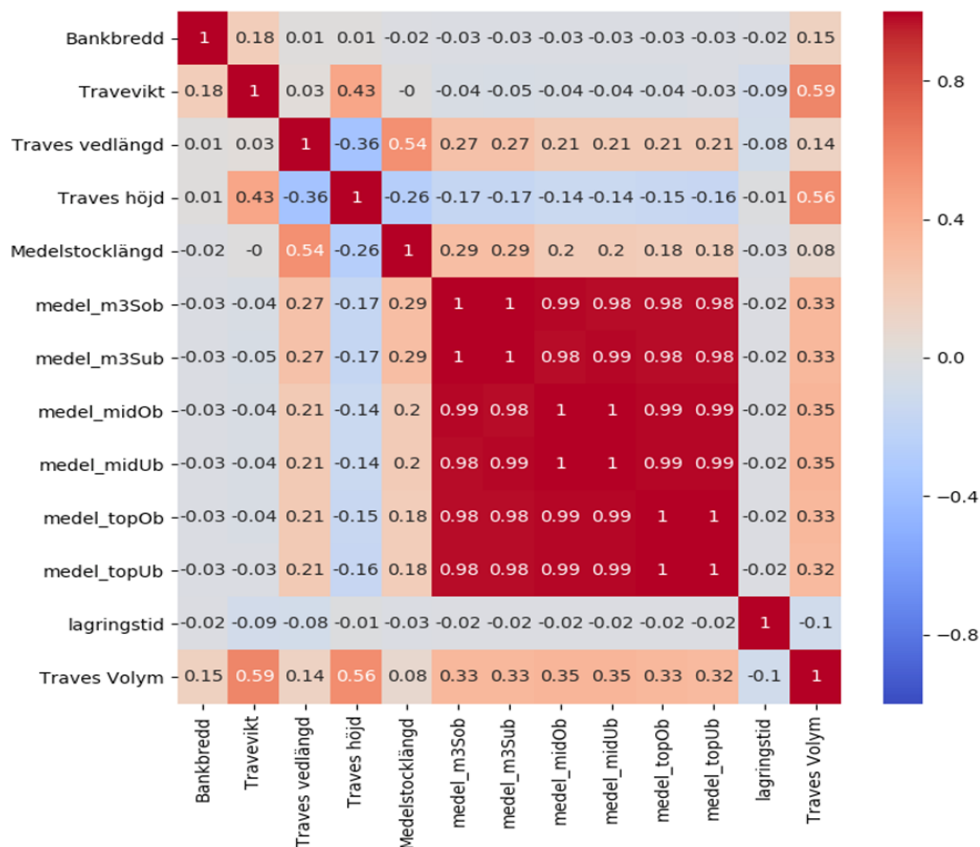
4 Resultat

4.1 Val av variabler till modellen

Kontinuerliga variabler

I figur 8 visas en korrelationsmatris för kontinuerliga variabler, dvs variabler som kan anta alla värden inom sitt variationsområde. Ett antal av dessa; medelvolym på och under bark, mittdiameter på och under bark samt toppdiameter på och under bark, var starkt korrelerade (de röda i mitten av figuren). Det betyder att modellen bara behöver en av dem. ”Toppdiameter på bark” valdes eftersom den hade minst antal saknade värden i datasetet. Även medelstocklängd från skördardata ($L_{ved-skördare}$) och travens vedlängd enligt AI-analys (L_{ved-AI}) hade en god korrelation ($p=0,54$). Båda beskriver längden av stockarna.

Korrelationsmatrisen visar även att variablerna travens vikt och travehöjd korrelerade med traves volym ($p=0,59$ och $0,56$ respektive). Högre vikt eller höjd betyder att volymen ökar. Det bekräftar att de är viktiga variabler att ha med i modellen. Däremot hade volymen svaga korrelationer med lagringstid och medellängd ($p=-0,10$ och $0,08$).



Figur 8: Korrelationsmatris för kontinuerliga variabler. Traves vedlängd och traves höjd från AI-analys av foto på traven.

Kategoriska variabler


Följande kategoriska variabler, dvs variabler som kan anta ett fåtal olika värden, användes i modellträningen: sortiment, månad, geografiskt ursprung. För kategoriska variabler är det

inte möjligt att beräkna korrelationsmatriser på det sätt som gjordes för kontinuerliga variabler, utan dessa analyserades enligt beskrivning nedan.

Val av variabler till modellen

När man jobbar med maskininlärning och data är det viktigt att inte ta med för mycket variabler i sin modell då det dels driver träningstiden för modellen (och därmed kostnaden för den processorkraft man behöver till träningen) samt att modeller har en högre risk för överanpassning om det tränas med för många variabler. Överanpassning innebär att man får en modell som klarar sig väldigt bra på sin tränings- och valideringsdata men som riskerar att prestera mycket sämre när det dyker upp problem som inte exakt liknar de den sett tidigare. Man vill ofta försöka få en enklare modell med färre variabler som har en bättre generaliseringsförmåga och därmed bättre kan klara av problem som den inte stött på tidigare men som delvis liknar problem den stött på tidigare.

Vid tillämpning av maskininlärning kan ett flertal olika statistiska värden användas som underlag när man beslutar vilka variabler som ska ingå i den modell man skapar, men i den aktuella studien har två valts ut; variabel-vikten (*feature importance*) och gemensam information (*mutual information*). En variabel-vikt kan beräknas genom att göra ett F-test som testar modellen X med alla värden konstanta vilket jämföras med modell Y, där man har samma konstanta värden men adderar en till variabel. Man kan då jämföra och se om en enskild variabel tillför något och är viktig att ha med i den slutliga modellen. Värden nära 0 betyder att en variabel förmodligen inte är signifikant för att bestämma målvariabeln i modellen, värden nära 1 betyder att en variabel är mycket viktig. Gemensam information (*Mutual information*) mellan två variabler mäter hur stor påverkan variablerna har på varandra, även om sambanden inte är linjära. T.ex. om X och Y är variabler som är helt oberoende av varandra; vi kan alltså inte veta något om X om vi känner till bara Y och vice versa. Gemensam information är därför 0.




Figur 9: P-värden för *feature importance* och *mutual information* för olika variabler i studien.

Figur 9 visar att travesens vikt och travehöjden var de viktigaste variablerna, följt av en grupp av tre variabler: sortiment, $D_{\text{to-skördare}}$, och $L_{\text{ved-skördare}}$. I den färdiga modellen för traves volym ingick totalt nio variabler (se tabell 3). Lagringstiden hade låg signifikans och togs därför inte med i modellen.

Tabell 3. I modellen ingående variabler.

Kontinuerliga variabler	Beteckning	Datakälla
Traves höjd	$H_{\text{trave-AI}}$	Bildanalys / AI
Traves vedlängd	$L_{\text{ved-AI}}$	Bildanalys / AI
Bankbredd	L_{bb}	Registeruppgift
Travevikt	M_{trave}	Fördelad lastvikt via bildanalys / AI
Medelstock-diameter	$D_{\text{to-skördare}}$	Från skördaren
Medelstock-längd	$L_{\text{ved-skördare}}$	Från skördaren
Kategoriska variabler		
Sortiment	SS	Från skördaren
Avverkningsmånad	$AVV_{\text{månad}}$	Från skördaren
Geografiskt ursprung	XY_{grid}	Från skördaren

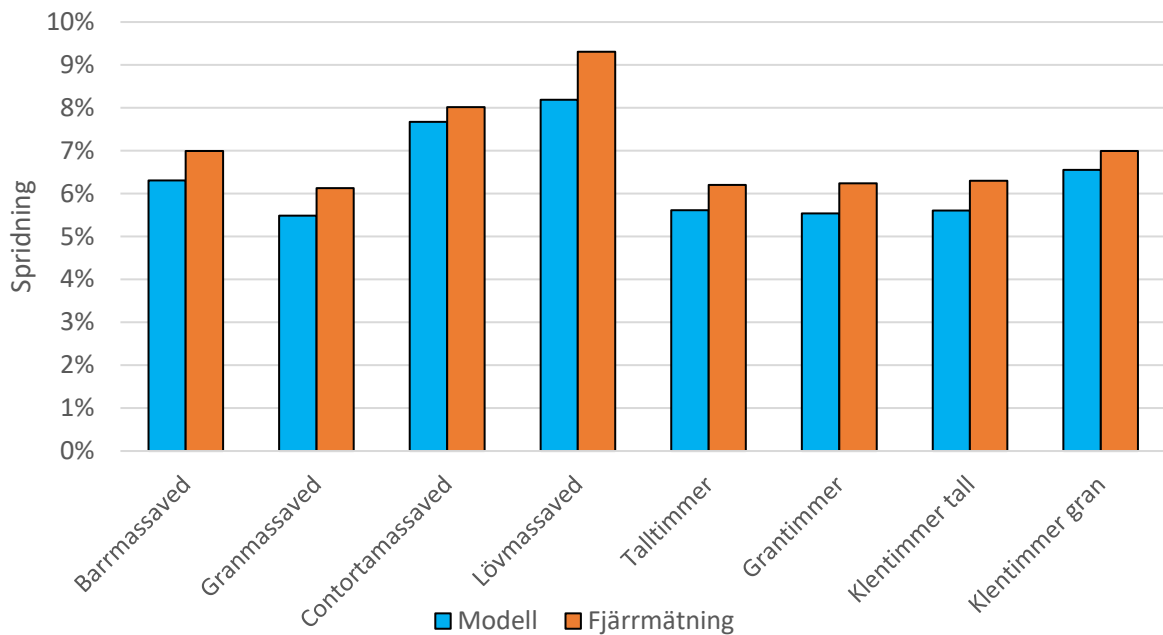
Modellen uppvisade en lägre standardavvikelse jämfört med fjärrmätning för samtliga sortiment medan den systematiska avvikelsen var på ungefär samma nivå som fjärrmätningen (Figur 10, 11).



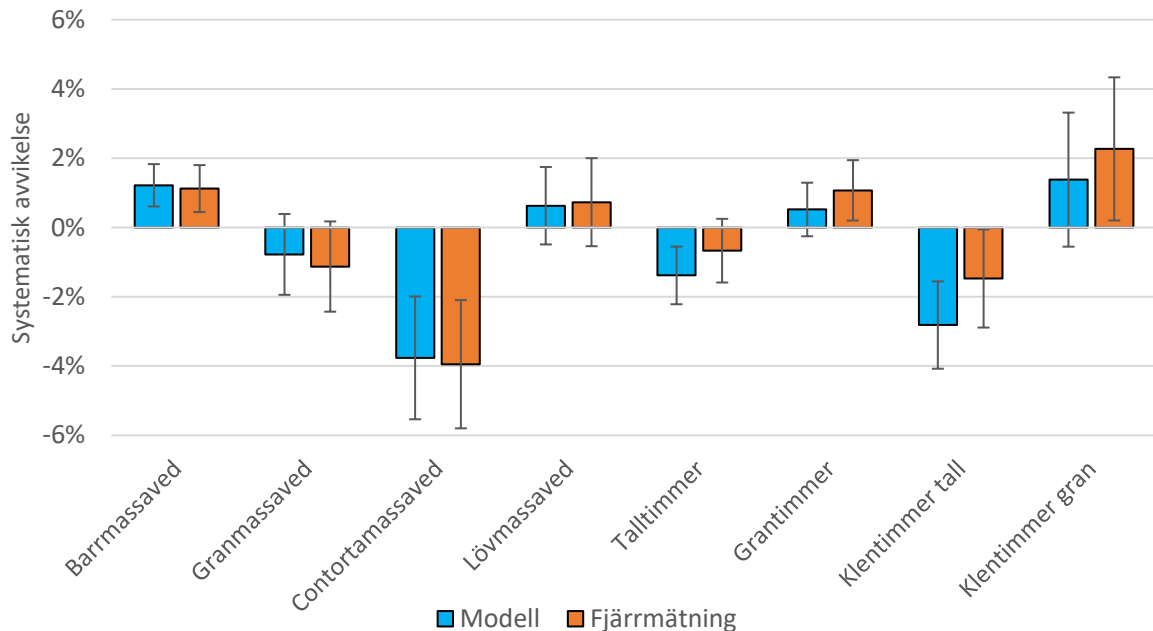
Figur 10. Systematisk avvikelse (inkl 95%-igt konfidensintervall) och standardavvikelse (spridning) för fjärrmätningen respektive den framtagna modellen för alla stockmätta referenstravar.

4.2 Utvärdering av modellens mätningens kvalitet per sortiment

Modellen gav mellan 0,3 till 1,1 %-enhet lägre standardavvikelse per sortiment jämfört med fjärrmätningen (figur 11). De systematiska avvikelserna uppvisade samma mönster som fjärrmätningen (figur 12).



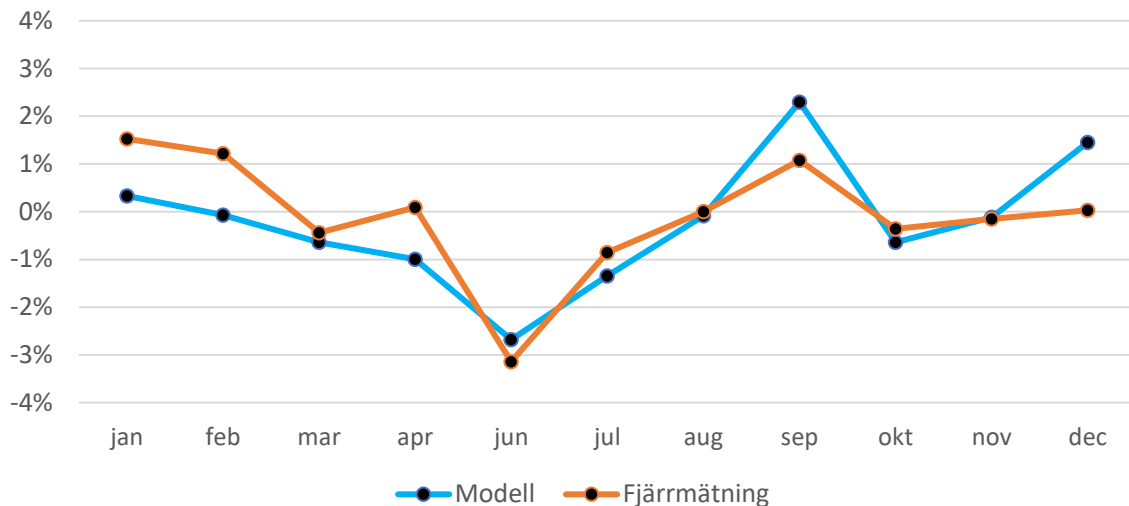
Figur 11. Standardavvikelse per sortiment uppdelat för modell respektive fjärrmätning. Endast sortiment med minst 40 stockmätta travar ingår.



Figur 12. Systematisk avvikelse per sortiment för modell och fjärrmätning samt ett 95%-igt konfidensintervall för den systematiska avvikelsen. Endast sortiment med minst 40 stockmätta travar ingår.

4.3 Systematisk avvikelse per månad

Modellen följde samma månadsvisa volymavvikelser som fjärrmätningen (figur 13). Underskattningen under försommaren beror troligen på ökat barkavskav vid avverkning under savningstid, vilket vid fjärrmätning leder till underskattning av vedvolymprocenten. Modellen i sin tur är tränad mot fjärrmätningen och upprepar därför samma misstag.



Figur 13. Månadsvis systematisk volymavvikelse mot stockmätta stickprovstravar för fjärrmätning respektive den framtagna modellen.

5 Diskussion och slutsatser

5.1 Den framtagna AI-modellen

I inledningen beskrevs att en traves volym kan bestämmas via travmätning (traves mått och vedvolymprocent) eller vägning med omvandlingstal. En fråga blir då vilken av dessa kategorier den framtagna AI-modellen tillhör. När arbetet inleddes var utgångspunkten att vikten var den viktigaste ingångsvariabeln och att AI-modellen därmed skulle bli en form av vägning. När man betraktar den framtagna modellen framstår det dock mer som att det är en AI-stödd travmätning.

Travmätning innebär att vi multiplicerar de tre travmåttarna och vedvolymprocenten. I den modell som tagits fram används bland annat:

- Travhöjd och vedlängd från AIDA (som bygger på att det finns bilder från fotorigg).
- Bankbredd/travlängd från bankbreddsregistret.

Då återstår vedvolymprocenten för att få traves volym. Det är främst här variablerna traves vikt, stocklängd_{skördare}, toppdiameter_{skördare}, sortiment, avverkningsmånad och plats i Sverige kommer in i bilden. Det innebär i så fall att de sex variablerna ger en något bättre bestämning av vedvolymprocent jämfört med vad mätarna gör. Men det kan också vara så att dessa sex variabler även förbättrar bestämningen av travhöjd, vedlängd, bankbredd.

Resultatet blir att standardavvikelsen sänks med ca 0,7 %-enheter jämfört med fjärrmätningen.

Modellen ger alltså inte ett omvandlingstal från vikt till volym utan blir snarare en automatisk travmätning där vikt ingår som en variabel för att nå volymen. Ett antal resultat pekar i den riktningen; t.ex. att lagringstid och månad inte var signifikant trots att man när man utvärderade den så kallade 5-2 mätningen kunde konstatera ganska stora månadsvisa skillnader, se t.ex. (Ölund & Selin, 1999). Man kan också i figur 13 tydligt se att modellen upprepar samma månadsvisa mönster som travmätningen uppvisar. Att resultatet blev sådant beror på att modellen tränats för att efterlikna den manuella travmätningen. Resultatet blir därför starkt knutet till hur bra eller dålig den manuella mätningen av respektive sortiment är, något som tydligt framgår av figurerna 11 och 12.

5.2 Förbättrat mätresultat med AI-modellen

Sänkning (förbättring) av standardavvikelsen är i snitt ca 0,7 %-enhet (mellan 0,34–1,12%-enheter beroende på sortiment). Detta innebär en väsentlig förbättring och för de sortiment där fjärrmätningens standardavvikelse ligger på 6–7 %, dvs timmer, barmassaved, granmassaved, når man nu spridningsnivåer kring eller under 6 %, vilket måste anses som ett mycket bra resultat. Andra projekt rörande utrustningar för automatisk travmätning har haft svårt att nå en sådan förbättring.

För lövmassaved och contortamassaved är sänkningen av standardavvikelsen på ungefär samma nivå men hamnar kring 8 % istället för cirka 6 % som övriga sortiment. Förbättringen är tydlig, men nivån på den uppnådda standardavvikelsen är mindre bra. Lövmassaved är svår att travmäta, med hög standardavvikelse som följd, samtidigt som det från många äldre studier är väl känt att man kan få bra resultat med vägningsmetoder. Även i Mittuniversitetets studie (som utgick från vikt), kap 2.2.1, blev den relativa förbättringen störst för lövmassaved. Nivån på standardavvikelsen för dessa sortiment beror på valet av metodik, där modellen tränats att efterlikna fjärrmätningen, vilket innebär att spridningen därifrån följer med in i den framtagna modellen.

5.3 Implementering av modellen

Lagkrav

Resultaten är så bra att den framtagna metoden ska kunna implementeras. Skogsstyrelsens föreskrifter om virkesmätning (SKSFS 2014:11) säger att ”vid virkesmätning får endast obetydliga systematiska fel förekomma”. Av figur 10 framgår att modellen, med avseende på de stockmätta travar mot vilken den utvärderades, hade mycket låg systematisk avvikelse, lägre än den fjärrmätning den jämförs med. Av figur 12 framgår dock att både modellen och fjärrmätningen för flera sortiment skiljer sig signifikant från 0 % avvikelse. Hur detta, samt de säsongsvisa variationerna, ska hanteras bör ingå som en del i fortsatta utredningar rörande implementering av modellen.

Föreskrifterna sätter även gränser för partivisa avvikelser. Den viktigaste komponenten för dessa är standardavvikelsen (spridningen) vid mätning av enskild trave. När den nuvarande mätningen utvärderats (SDC/VMU 2016) har det visats att en mycket hög andel av virkespartierna klarar lagkraven, dock inte 100 % av dem. Den sänkning av

standardavvikelsen som föreliggande studie visar borde leda till att laguppfyllnaden kommer ännu närmare 100 %.

Begränsningar

En kommande implementering kommer att ha ett antal begränsningar:

1. Både skördardata och foton från bildrigg måste finnas tillgängliga.
2. Hela fordonslasten måste bestå av en leverans (ett RNR), dvs komma från samma avverkning. Vid olika former av samlastning måste annan mätmetod tillämpas.
3. Eftersom bankbredden hämtas från register måste detta kvalitetssäkras. Det inkluderar att kunna säkerställa att dragbil och släp utgör den kombination som kan finnas i registren.

Kontrollmätning och VMK-godkännande

Vad gäller kontroll av travmätningen blir det ingen skillnad mellan nuvarande fjärrmätning och den nya metoden för AI-stödd travmätning. Men eftersom man generellt kan säga att behovet av kontrollobjekt sjunker med ökande noggrannhet i den ordinarie mätningen, kan man säga att den AI-stödda travmätningen bör medföra sänkt kostnad för kontrollmätning.

Den nya metoden för AI-stödd travmätning behöver godkännas av VMK.

5.4 Idéer för kommande studier och utökad implementering av metoden

Träna modellen på travar som stockmätts

Bäst vore att kunna träna modellen på data från stockmätning, dvs på noggrant volymbestämda travar där man också har en säker vikt från en särvägning av traven. Då skulle man slippa att få en modell som "härmar" den manuella mätningens osäkerhet. Detta är extra angeläget för lövmassaved och contortamassaved som uppvisar den högsta spridningen med den aktuella modellen. Mängden särvägda travar som sedan stockmätts är dock avsevärt färre än de datamängder som ingått i denna studie för att träna modellen.

Analys per fordon istället för per trave

Vägning av fordon med ett visst antal travar ger en totalvikt för alla travarna. Att använda "AI-rektanglarna" för att fördela vikten på ingående travar tillför en spridning som i sin tur försämrar resultaten jämfört med om vikten varit mer exakt bestämd för enskild trave. För virkesaffären och den aktuella leveransen finns det ingen anledning till uppdelning på travar. Hela kvantiteten på leveransen är den logiska måtenheten när det handlar om vägning. Först vid samlaster, dvs flera leveranser på samma fordon, blir det nödvändigt att fördela vikten. För kommande studier kan man fundera på att göra fordonsvisa analyser. Målvariabel blir då summa volym för alla travar på fordonet. Uppdelning på krantravar respektive travar utan kran behövs då inte. Det behövs inte heller någon AI-funktion för rektangelmått. Utmaningen då blir istället kontrollsteget då vägd volym ska jämföras med stockmätt volym.

Utökad implementering av metoden

Som beskrivits ovan finns flera sätt att vidareutveckla metoden, och därmed få ännu tydligare motiv för utökad implementering. Ett första sätt är om ännu bättre noggrannhet uppnås om/när modellen kan tränas på stockmätta travar. Detta kan få särskild betydelse för lövsortiment.

Ett andra sätt är att utveckla metoden så att den kan tillämpas även för samlastade fordon. För detta kan flera utvecklingsvägar tänkas:

1. När samlastningen avser hela travar kan fordonet vägas om efter lossning av respektive leverans, dvs att varje leverans särvägs.
2. Utveckla en modell där vikt inte ingår. Att kunna utveckla en sådan modell, som ger acceptabel noggrannhet, har störst sannolikhet för lövsortiment och när modellen baseras på stockmätta travar.
3. Träna AIDA att även identifiera samlastar och mäta dessa separat.

6 Litteraturförteckning

Carratú, Marco, Liguori, C., Pietrosanto, A., O'Nils, M., & Lundgren, J. (2019). Data fusion for timber bundle volume measurement. *2019 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*. Auckland, New Zealand: IEEE.

Finnström, C., Jägbrant, S., & Lenaers, P. (2018). *Mätning av travmått med hjälp av objekt-detektering*. Sundsvall: SDC.

SDC/VMU 2016. Projektrapport för VMU-projekt Partivis noggrannhet.

SKSFS 2014:11. *Skogsstyrelsens föreskrifter om virkesmätning*. Skogsstyrelsens författningssamling.

Strömgren & Björklund, 2019. *Utkast till formelsamling för VIOL 3*.

Ölund, U., & Orvér, M. (1998). *Vikt som hjälpmedel vid volymmätning*. Umeå: VMF Nord.

Ölund, U., & Selin, P. (1999). *Vikt som hjälpmedel vid volymmätning*. Umeå: VMF Nord.