


Automatisk kvantifiering av fetved hos tall

Kari Hyll, Sheng Joevenller, Henrik Svennerstam, Fredrik Nysjö, Olof Broman, Johan Oja, Dick Sandberg



CT-skannad tallstock, där det rosa området visar kärnved och det ljusgrå fetved orsakad av törskateangreppet.

Innehåll

Förord	4
Summary	5
Sammanfattning	7
Bakgrund	9
Törskateproblematiken	9
Resultat från tidigare projektet	9
Syfte och mål	10
Material och metoder	11
Stockdata	11
Bildanalysmetod	11
Förbearbetning	11
Segmentering och klassning	12
Efterbearbetning	13
Valideringsmetoder	17
Terminologi.....	17
Klassning av enskilda bilder	18
3D-analys (connected components).....	20
Resultat	22
Träffsäkerhet	22
Klassning av enskilda bilder	22
Klassning av hela stockar	25
Infektionsingångshöjd vs. masscentrumshöjd.....	26
Volymandel fetved	27
Effektivitet och processeringshastighet.....	28
Diskussion	29
Noggrannhet och träffsäkerhet	29
Antalet törskaterelaterade fetvedsområden	29
Överklassning av fetved.....	29
Underdetektering av fetved	33
Fetvedsområdets masscentrumshöjd och längd	36
Kådanrikad kärnved	37
Fetved med hög densitet	37
Användbarhet i sågverk	37

Slutsats och resultatsammandrag.....	38
Referenser.....	39
Appendix.....	40



skogforsk

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

Kvalitetsgranskning (Intern peer review) har genomförts oktober månad 2023 av Johan J. Möller, vice programchef.
Därefter har Magnus Thor, Forskningschef,
granskat och godkänt publikationen för publicering 1 februari 2024.

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

Förord

Författarna sänder ett stort tack till Gunnar Hedlunds Hedersfond via Norras Forskningsstiftelse för deras finansiella bidrag till specifikt detta projekt. Vi tackar också Knut och Alice Wallenberg Stiftelse för deras finansiella bidrag till National Bioinformatics Infrastructure Sweden (NBIS) Long-Term Support, samt och Stiftelsen för Strategisk Forskning för deras finansiella stöd till det relaterade doktorandprojektet som leds av Sheng Joevenller. Slutligen tackar vi forskarna vid institutionen för skoglig mykologi och växtpatologi vid SLU och alla de kollegor som engagerat sig och bidragit till projektet.

Uppsala november 2023
Projektledare Kari Hyll

Summary

Sawlogs that exhibit resin wood due to pine-blister rust infection are anticipated to become increasingly prevalent, particularly in the northern regions of Sweden. Presently there are no automated procedures for measuring resin wood in sawmills. The goal of this project was to develop such a method.

The developed method detects and quantifies resin wood and other rust-related reaction wood in X-ray images of pine timber logs. The method is based on scanning logs with X-ray computed tomography (CT), which provides a 3-dimensional digital reconstruction in which the resin wood can be identified. The identification process relies on an algorithm that amalgamates various image analysis techniques, subsequently followed by a post-processing routine. The algorithm was developed in the Python programming language and ported into the C++ programming language to achieve increased processing speed. The results of the algorithm consist of a classification of the log volume into the classes: heartwood, healthy sapwood and resin wood caused by the blister-rust infection. A post-processing step is then applied. The additional post-processing routine refines the results based on the characteristics of the infection, addressing misclassifications that may occur, particularly when resin wood is detected far from the outer perimeter of the log volume.

The method was validated on logs with and without resin wood due to blister rust, partly on individual images, partly on entire log volumes. In the first case, the algorithm's classification of the wood types was compared with manually classified images. The same image set was manually classified by three individuals. In the second case, a so-called connected component analysis was applied to whole logs. The count, length and centre-of-mass height of the resin wood components were compared with manual assessment of the component count and length and entry height of the fungus in the tree. The validation result shows that:

- The algorithm is useful for classifying logs into resin-wood logs and logs without considerable amount of resin wood. At the log level, the algorithm correctly classifies 58–78% of the logs without the post-processing step, and 83–89% when the post-processing routine was used.
- At the cross-section level, the accuracy of the algorithm according to the average of the two validation indices SMAPE and DICE for the three classes heartwood, sapwood and resin wood was 84%, 96% and 45%, respectively.
- The algorithm over-detects the amount of resin wood, mainly by confounding the edge of the heartwood with resin wood and by classifying certain very dark growth rings as resin wood. As a consequence, the volume and length of the resin wood components were overestimated.
- Some under-detection of resin wood occurs, partly in case of very strong resin wood formation where the resin wood density becomes as high as the green sapwood, partly when small, peripheral areas of resin wood are size-filtered away.
- The algorithm's calculation of the center of mass height for each resin-wood component offers potential markers for identifying the point of entry of the blister rust infection into the tree.
- The algorithm's measurements of resin-wood component lengths show significant discrepancies when compared to visually assessed lengths, likely due to a combination of previously mentioned factors.

- A post-processing routine based on the typical spatial distribution of the resin wood can be used to refine the classification, especially for logs without external signs of rust infection.
- In summary, the algorithm can be used to identify whole logs with resin wood as a result of blister-rust infection, with a relatively high accuracy.

However, when the algorithm misclassifies a log, it tends to be oversensitive, classifying healthy logs as fatwood logs, rather than undersensitive. The oversensitivity must be lowered. Additionally, the laboratory-based algorithm is still too slow for industrial application. Therefore, the next development step is to develop a machine-learning algorithm, preferably based on neural networks, which is expected to be both faster and better able to consider the change in shape of the log due to blister rust infection. Examples of important parameters for classifying resin wood are expected to be pith position, distance between the pith and the resin wood, and the distance between the mantle surface and the resin wood. The bark should potentially be put as a separate class as it has a similar density to the sapwood. Even resin wood with a very high density should possibly have its own class.

Sammanfattning

Sågtimmer med fetved¹ till följd av törskateangrepp väntas bli vanligare, särskilt i norra Sverige. Idag saknas automatiserade metoder för att mäta denna typ av fetved. Målet med projektet var att ta fram en sådan metod.

Den utvecklade metoden använder röntgenbilder för att detektera och kvantifiera fetved och annan reaktionsved i sågtimmer av tall till följd av törskateangrepp. Metoden baseras på att stockar skannas med röntgenbaserad datortomografi (CT-skanning) vilket ger en 3-dimensionell digital rekonstruktion i vilket törskateangreppet kan identifieras. Metoden för identifiering av törskateangreppet består av en algoritm som kombinerar ett antal bildanalystekniker samt ett efterbearbetningssteg. Algoritmen utvecklades i programmeringsspråket Python och överfördes sedan i programmeringsspråket C++ för att öka processeringshastigheten. Algoritmens resultat består av en klassning av stockvolymen i kärnved, frisk splintved och fetved. Därefter tillämpas ett efterbearbetningssteg. Efterbearbetningssteget utgår från törskatens patologi och observationen att infektionen börjar vid mantelytan och sprider sig in i stocken. Om algoritmens resultat innehåller fetved som inte har någon närliggande kontakt med mantelytan kan dessa antas vara felklassningar, vilka efterbearbetningssteget korrigerar.

Metoden validerades för stockar med och utan fetved till följd av törskate, dels på enskilda bilder, dels på hela stockvolymen. I det första fallet jämfördes algoritmens klassning av bildernas vedtyper med manuellt klassade bilder. Samma bilder klassades manuellt av tre individer. I det andra fallet gjordes en så kallad connected component-analys på hela stockar och komponenternas antal, masscentrumshöjd och längd, vilka jämfördes med manuell bedömning av antal, längd respektive törskatesvampens ingångshöjd i trädet. Valideringsresultatet visar att:

- Algoritmen är användbar för att klassa stockar i fetvedsstockar respektive normalstockar. På stocknivå klassar algoritmen rätt för 58–78 procent av stockarna då efterbearbetningssteget inte används, och för 83–89 procent då efterbearbetningssteget används.
- På tvärsnittsnivå är algoritmens träffsäkerhet enligt medelvärdet av de två valideringsmåten SMAPE och DICE för de tre klasserna kärnved, i splintved och fetved 84, 96 respektive 45 procent
- Algoritmen överskattade mängden fetved, huvudsakligen genom att sammanblanda kärnvedens gräns mot splintveden med fetved samt genom att klassa vissa mycket mörka årsringar som fetved.
- Viss underskattning av fetved förekommer, dels vid mycket kraftig fetvedsbildning där kådvedsdensiteten blir lika hög som splintvedsdensiteten för rått trä, dels då små, perifera fetvedsområden trösklas bort på grund av deras begränsade utbredning.
- Den masscentrumshöjd som algoritmen ger för varje fetvedskomponent ger en skattning av den höjd där törskateinfektionen bedöms ha gått in i trädet.

¹ Extra kådrik ved hos tall som uppstått efter en skada eller angrepp. Fetved räknas ibland som ett virkesfel vilket sänker värdet på den sågade råvaran. Den kådrika veden har dock höge beständighet mot röta vilket också kan utgöra en möjlighet.

- Den av algoritmen givna längden för varje fetvedskomponent överensstämmer dåligt med den visuellt bedömda längden vilket beror på en kombination av tidigare nämnda faktorer.
- Ett efterbearbetningssteg baserat på fetvedens typiska rumsliga utbredning kan användas för att förbättra klassningen, särskilt för stockar utan yttre tecken på törskateangrepp.
- Sammanfattningsvis kan algoritmen identifiera om stockar har fetvedsförekomst till följd av törskateangrepp, med god noggrannhet.

När algoritmen felklassar en stock tenderar den dock att vara översensitiv, det vill säga klassa normalstockar som fetvedsstockar. Denna översensitivitet måste minskas. Den laboratoriebaserade algoritmen är även för långsam för industriell tillämpning. Därför är nästa utvecklingssteg att utveckla en maskininlärnings-algoritm, lämpligen baserat på neurala nätverk², som både förväntas vara snabbare och bättre kunna ta hänsyn till stockens förändrade form till följd av törskateangreppet. Exempel på viktiga parametrar för att klassa fetved förväntas vara märgdetektion, avstånd mellan märgen och fetvedsområdet, samt mellan mantelytan och fetvedsområdet. Barken bör potentiellt klassas som en separat klass då den har densitet i samma nivå som fetveden. Även fetved med mycket hög densitet bör eventuellt ha en egen klass.

² Ett samlingsnamn för metoder inom artificiell intelligens som genom behandling av data har förmågan att lära sig av erfarenhet.

Bakgrund

Törskateproblematiken

Törskate (*Cronartium pini* spp.) är en rostsvamp som angriper tall. Två undertyper av törskate har identifierats i nordiska skogar; en värdväxlande form som är beroende av ytterligare en art för att fullborda sin livscykel, samt en kronal form som angriper trädets övre del. Den främsta värdväxten för törskate i Sverige anses vara Kovall (*Melampyrum* spp.) (Metla 2007; Adolfsson 2022). De olika törskatevarianterna förekommer generellt i skilda geografier med dominans av den värdväxlande formen i norra Sverige, men båda varianterna har även påträffats i samma bestånd.

Infektionen kommer in i trädet genom framför allt årsbarr, men det är även möjligt att infektion kan ske via färska skott eller skador (Kim m.fl. 2022). Svampen tar sig till innerbarken där den nyttjar trädets vatten och näringsämnen. Tallen försvarar sig genom att berika intilliggande ved med extraktivämnena (kåda), vilket resulterar i så kallad fetved. Det är i nuläget oklart om svampen stannar i innerbarken eller även förekommer i själva fetveden. Kådanrikningsprocessen stoppar transporten av vatten och näringsämnen i den infekterade delen av trädet, vilket stoppar tillväxten i det angränsande kambiet (trädets tillväxtskikt precis innanför barken). Svampens utveckling i trädet är relativt långsam, med en tillväxt i storleksordningen centimetrar per år (Kaitera 2000). Kampen mellan träd och svamp kan därför vara utdragen och spänna över flera decennier.

En del av de överlevande träden når dimensioner som är lämpliga för sågning och detta sågtimmer kan innehålla fetved som bildats på grund av infektionen. Infektionen kan synas på trädstammens utsida som orangefärgade fläckar under perioder då svampen är sporbildande, eller som svarta zoner, kådrinningar, eller lös bark. Det är dock möjligt för trädet att övervalla skadan, vilket kan göra den i stort sett osynlig från utsidan. Infekterade träd kan också utveckla betydande asymmetri i stammens tvärsnitt.

Fetveden har egenskaper som är oönskade för användning i de flesta furuprodukter (Kaitera m.fl. 1994). Timmer med synlig törskaterelaterad fetved får enligt klassningsreglerna för rundvirke inte användas som sågtimmer eller massaved utan ska nedklassas till bränsleved. Trots detta kommer törskateskadade stockar in till sågverksprocessen. Uppskattningar har visat betydande ekonomiska effekter av törskate, med sågutbytesförluster mellan 22 och 34 procent, och upp till 18 procents förlust i marknadsvärde för det sågade virket (Kaitera m.fl. 1994).

De två i Sverige hårdast drabbade regionerna, Norrbotten och Västerbotten, har cirka 150 000 ha törskateinfekterad skog (Stenlid 2021). Andra regioner, exempelvis norra Finland, är också påverkade, men i mindre utsträckning (JMMI 2012; Eriksson m.fl. 2016). Det befaras även att förekomst av törskate i Sverige är på uppgång och att spridning sker söderut (JMMI 2012) även om helt säkra data saknas (Gramner & Jernberg 2022). Ökningen tros vara kopplad till klimatet, där i synnerhet varma och fuktiga höstar antas gynna sporbildning och spridning av både svamp och värdväxterna (Samils & Stenlid 2022).

Resultat från tidigare projektet

En förstudie genomfördes med målet att bestämma möjligheten att detektera törskateskadat timmer med hjälp av röntgenbaserad datortomografi (CT-skanning) för att

därmed kunna optimera sågningen och ”rädda” det sågade virkets värde (Hyll m.fl. 2022). Förstudien visade att:

1. Törskaterelaterad fetved kan detekteras med hjälp av CT-skanning på ett sätt som möjliggör fortsatt utveckling av en industriell optimering av timrets sönderdelning.
2. Det är tydligt att törskaterelaterad fetved i allmänhet har en större utbredning i stammen än det synligt angripna området på stammens mantelyta.
3. Fetvedens utbredning kan klassas i två kategorier: central och perifer, där den centrala sträcker sig från mantelytan ända in mot kärnveden, medan den perifera endast återfinns nära barken. Den centrala utbredningen ligger ofta nära där svampen först attackerade trädet (ingångshöjden), där fetvedens utbredning oftast också är som störst. Perifer utbredning ligger ofta på större avstånd från ingångshöjden i stammens längdriktning.
4. Kärnved och fetved har snarlika bildanalystekniska egenskaper, vilket försvårar en separering av dessa vedtyper.

Inom förstudien fanns inte utrymme för att i detalj analysera törskateangreppens utbredning i stammen och inte heller kunde ett bildbehandlingsverktyg för att automatiskt skilja fetved från övrig ved. Resultaten visade dock att röntgen är en framkomlig väg för industriell detektering av törskaterelaterad fetved. En provtagning för att identifiera törskateinfektionens utbredning gjordes med hjälp av DNA-analys som visade att törskatesvampen inte har samma utbredning som den fetved som svampen orsakar. Törskate-DNA återfanns även i angränsande oskadad splintved. Detta visar på svårigheten att skilja mellan detektion av törskateinfektion respektive detektion av fetved till följd av törskate.

Syfte och mål

Arbetet som redovisas i denna rapport syftar till att ge skogsägare och sågverk möjlighet att öka virkesvärdet hos törskateangripet virke. Målsättningen var att ta fram en automatiserad metod för att detektera och kvantifiera reaktionsved till följd av törskateangrepp på svensk tall (*Pinus sylvestris* L.).

Material och metoder

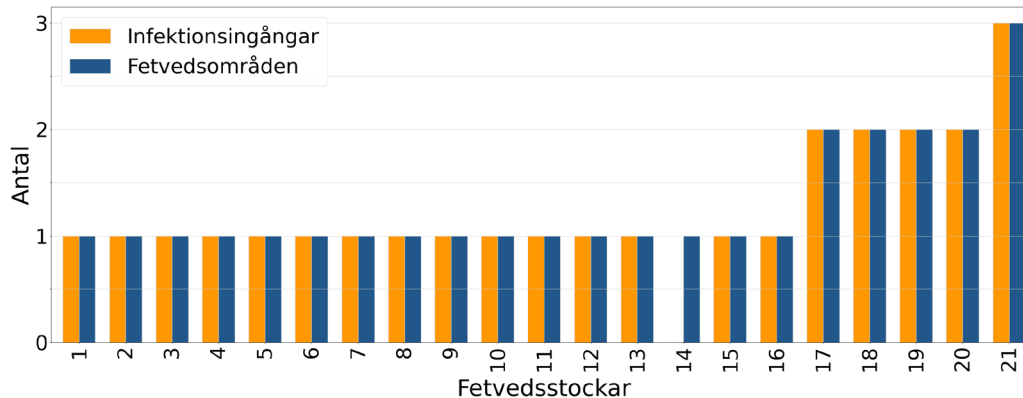
Stockdata

Stockdata bestod av tre set med totalt 36 CT-skannade tallstockar av följande ursprung:

- A. Fjorton stockar från fem stammar från ett törskateangripet gallringsbestånd, varav en referensstam som inte hade yttre tecken på törskateangrepp.
- B. Sexton stockar från fem stammar från ett törskateangripet slutavverkningsbestånd, varav en referensstam som inte hade yttre tecken på törskateangrepp.
- C. Sex referensstockar från okända bestånd, samtliga utan yttre tecken på törskateangrepp.

Stockarna i grupperna A och B namngavs enligt mönstret *stam-stock*, exempelvis 8-2 medan stockarna i grupp C namngavs med en förkortning av filnamnet som erhöles vid skanningen. Stockarna i grupperna A och B samt skanningsinställningar beskrivs närmare i Skogforsk Arbetsrapport 1126-2022 (Hyll m.fl. 2022).

Baserat på visuell bedömning av CT-bilderna innehöll 21 (58 %) av de 36 stockarna fetvedsområden som med hög sannolikhet var orsakade av törskate, medan övriga 15 (42 %) stockar inte hade synliga spår av törskateangrepp av något slag. Fem av de 21 fetvedsstockarna hade fler än ett fetvedsområde och alla utom ett gick att koppla till en infektionsingång i samma stock (Figur 1).



Figur 1. Visuell räkning av antalet fetvedsområden respektive infektionsingångar.

Bildanalysmetod

Förbearbetning


Data från CT-skanningen har filformatet BigTiff, lagrat i en 2D-struktur. Efter att filen omformats till en 3D-stack tillämpades en brus borttagningsmetod baserat på 2D-morfologisk öppning (erodering följt av dilatering) för att ta bort bilddata som inte kan kopplas till stocken. Förbearbetningen beskrivs ytterligare i Hyll m.fl. (2022).

Segmentering och klassning

Segmenteringen av bilddata i klasserna kärnved, splintved och fetved baserar sig på en semi-övervakad tröskling av modifierade bildintensitetsvärden. Den utvecklade segmenteringsmetoden är uppdelad i två steg:

1. Beräkning av en sannolikhetskarta (heatmap) för kärnved i ett tvärsnitt av CT-bilden.
2. Tröskling av sannolikhetskartan för kärnved samt av en lågpasfilterad version av det ursprungliga CT-bilddatat, vilka kombineras till en slutlig segmenteringsmask som klassificerar pixlar som antingen bakgrund (luft), splintved, fetved eller kärnved.

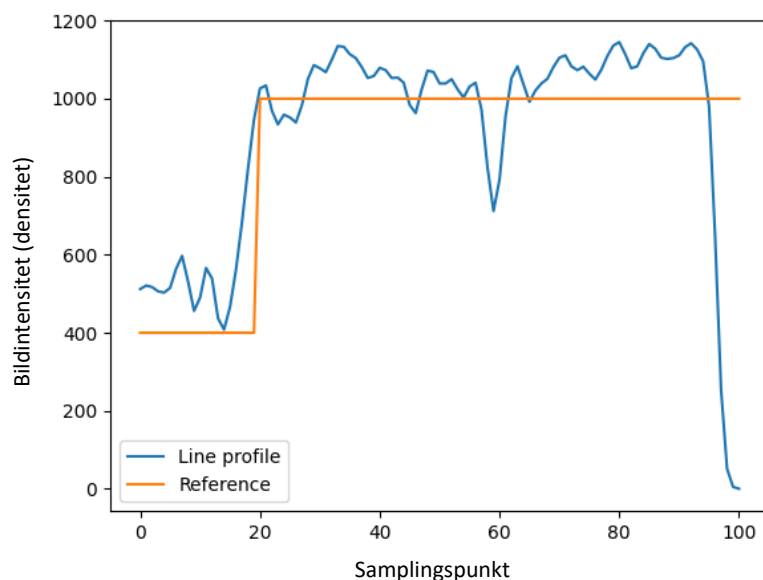
I första steget, beräkning av sannolikhetskartan för kärnved (Figur 2), används en metod som hämtat inspiration från hur ambient occlusion inom datorgrafik (Gross & Pfister 2007) och visualisering beräknas för ljussättning. Ambient occlusion är ett mått på hur synlig för inkommande ljus en viss punkt i rummet är när man tittar på integralen av alla strålriktningar i en sfär eller hemisfär kring punkten. Då synligheten i en strålriktning kring en punkt kan vara mycket tidsmässigt kostsam att beräkna, används ofta stokastisk sampling där endast ett mindre antal strålar kastas i slumpmässiga riktningar (kombinerat med ett lågpasfilter i ett efterbehandlingssteg för att reducera brus) för att uppskatta integralen. I stället för synligheten längs varje stråle som i ambient occlusion, tittar vår metod på absolutdifferensen mellan bildintensitetsprofilen samplad längs strålen (blå linje i Figur 3) kring en pixel och en ideal intensitetsprofil för kärnved omgiven av splintved (orange linje i Figur 3). Differenserna ackumuleras för varje pixel, och viktas även med en normaliserad avståndskarta för att undvika att fetvedspixlar nära barken på stammen av misstag klassificeras som kärnved. I nuvarande implementering används åtta randomiserade strålar per pixel i ett tvärsnitt, vilket visas i Figur 2.



Figur 2. Vänster: illustration av randomiserade strålriktningar som samplas för en pixel i steg 1 i segmenteringsalgoritmen. Höger: framställd heatmap som steg i segmenteringsalgoritmen, baserat på tvärsnittsbild från stock 1-2 på en höjd av 2,45 m från stockens toppände.

I andra steget utförs tröskling av sannolikhetskartan för kärnved samt av det ursprungliga CT-bilddatat, för att bestämma varje pixels slutliga klass i segmenteringsmasken. För sannolikhetskartan (som inte innehåller normaliserade sannolikhetsvärden) används 80 procent av maxvärdet som tröskelvärde för initial klassificering av pixlar som kärnved; här appliceras även ett extra dilateringssteg samt beräkning av kärnvedens konvexa hölje. För det ursprungliga CT-bilddatat appliceras först ett lågpasfilter och därefter tröskling med ett heuristiskt valt tröskelvärde för initial klassificering av pixlar som fetved (vilket

även kommer att inkludera kärnvedspixlar med liknande intensitet). Slutligen används skärningen av de bägge trösklingarna för att separera kärnved från fetved. Resterande pixlar med intensitet större än noll som varken är kärnved eller fetved klassas som splintved.



Figur 3. Exempel på samplad intensitetsprofil (blå linje) och ideal intensitetsprofil för kärnved omgiven av splintved (orange linje) för en av de randomiserade strålriktningarna för en pixel från ett tvärsnitt i stock 1-2.

Tabell 1. Tröskelvärde för klasserna, baserat på tester på stockar från stam nummer 1.

	Kärnved	Splintved	Fetved
Tröskelvärde	0–400	400–1000	>1000

För att förbättra formen på kärnveden beräknas och adderas dess konvexa skal.

Efterbearbetning

Efterbearbetningens främsta syfte var att åtgärda klassningsproblem kring kärnveden, där typfallet är att 1) att kärnved klassas som fetved, samt 2) kärnveden har splintvedsklassade områden. För att minska fetvedsklassning av kärnved användes observationen att törskateinfektionen utgår från mantelytan och söker sig inåt i stammen. En del av volymen hos ett törskaterelaterat fetvedsområde kommer därför alltid att ligga nära mantelytan. Det medför att om en fetvedsvolym angränsar till kärnveden men inte till mantelytan så är det osannolikt att den är "sann fetved" orsakad av törskate.

Då viss övervallning av fetved har observerats behövs en buffertzona när överlappet mot mantelytan ska beräknas. Buffertzonen beräknades som:


$$B = 0.4(R_{EQ,LOG} - R_{EQ,HW}) \quad [1]$$

där $R_{EQ,LOG}$ och $R_{EQ,HW}$ är stockens respektive kärnvedens ekvivalenta radier, vilka beräknades:


$$R_{EQ} = \sqrt{V/\pi L} \quad [2]$$

där L är stockens längd i pixlar och V dess volym i voxlar. Buffertzonen tillämpades genom binär morfologi, där en 3D-erodering med buffertbredden subtraherades från stockens binära mask. Skadekomponenterna extraherades genom "connected-component analys" med Python-paketet "dask-image". Alla skadekomponenters överlapp med buffertzonen beräknades sedan. Då algoritmen tenderar att klassa kvistcentra som fetved gjordes en volymjämförelse av de ytöverlappande komponenterna. Om en komponents överlapp var mindre än buffertbredden i kubik dividerat med två antogs den vara kvist, och dess överlapp mot ytan klassades om till splintved.


Angränsning mot kärnveden beräknades genom att 3D-dilatera kärnvedens binära mask med en voxel och sedan beräkna överlappet mellan alla skadekomponenter och den dilaterade kärnveden. Om överlappet mot kärnveden var större än fem voxlar och överlappet mot mantelytans buffertzona inte var större än fem voxlar klassades komponenten om till kärnved. Om både överlappet mot kärnveden och mot mantelytans buffertzona var mindre än fem voxlar klassades komponenten om till splintved. Skillnaden av efterbearbetningen blir generellt sett liten för stockar som har synlig fetved i CT-bilderna, och stor för stockar som inte har synlig fetved, vilket demonstreras i Figur 4 - till Figur 6.



Figur 4. Exempel på efterbearbetning av referensstocken 4-11-2, utan synliga fetvedsområden. Tvärsnitt från höjd $z=7258$ voxlar. Övre höger: originalbild. Övre vänster: mantelytans buffertzona samt kärnvedens kant. Mitt vänster: algoritmens klassning, där kärnvedsklassen är ljusgrå, fetvedsklassen mellangrå, och splintvedsklassen mörkgrå. Mitt höger: efterbearbetningens resultat. Nedre: algoritmens klassning i xz-planet, där det gröna strecket markerar var i stocken de övriga bilderna är tagna.



Figur 5. Exempel på efterbearbetning av törskateangripen stock nr 6-3, med ett relativt litet synligt fetvedsområde. Tvärsnitt från höjd $z=5197$ voxlar. Övre vänster: originalbild. Övre höger: Mantelytans buffertzona samt kärnvedens kant. Mitten vänster: algoritmens klassning, där kärnvedsklassen är ljusgrå, fetvedsklassen mellangrå, och splintvedsklassen mörkgrå. Mitten höger: efterbearbetningens resultat. Nedre: algoritmens klassning samt connected component-färgläggning i xz -planet, där det gulastrecket markerar var i stocken de övriga bilderna är tagna.



Figur 6. Exempel på efterbearbetning av referensstock 3-9-3, utan synlig fetved. Tvärsnitt från höjd $z=7081$ voxlar. Övre vänster: originalbild. Övre mitt: algoritmens klassning, där kärnvedsklassen är ljusgrå, fetvedsklassen mellangrå, och splintvedsklassen mörkgrå. Övre höger: efterbearbetningens resultat. Nedre: efterbearbetningens resultat samt connected component-färgläggning i xz-planet, där det gröna strecket markerar var i stocken de övriga bilderna är tagna.

För att minska antalet hål tillämpades 3D-morfologisk stängning (closing) av kärnvedsklassen, där buffervärdet var en och en halv gånger den ekvivalenta radien hos kärnveden.

Valideringsmetoder

Terminologi

De av algoritmen klassade områdena kallas i rapporten för zoner när de analyseras i 2D (för enskilda bilder) och komponenter när de analyseras i 3D. Områdena delas in i tre kategorier:

1. Rättklassningskandidater: fetvedsklassade områden vars utbredning kan länkas till visuellt synlig fetved.
2. Överklassningskandidater: fetvedsklassade områden som varken kan länkas till en yttre skada eller till fetvedsliknande densitetsförändringar i CT-bilderna
3. Underklassningskandidater: områden som inte är klassade som fetved men som kan länkas till yttre törskaterelaterad skada eller inre fetvedsliknande densitetsförändringar i CT-bilderna.

Hela stocken kan sedan klassas med två villkor, totalvillkor eller komponentvillkor. Totalvillkoret ser till hela mängden skada i stocken och kan ses som ett snabbt och funktionellt villkor av den typ ett sågverk skulle kunna använda för sortering. Komponentvillkoret ser till enskilda komponenters storlek och position och är användbart för en mer detaljerad sortering, för postning, för patologisk utvärdering av en stock, samt i denna rapports fall för validering av algoritmens räkning av antal komponenter och bestämning av deras längd- och masscentrum.

Om en stock uppfyller antingen totalvillkoret eller komponentvillkoret kallas den för en fetvedsstock. Om den inte gör det kallas den för en normalstock.

Klassning av enskilda bilder


175 bilder från 28 stockar klassades manuellt i det webbaserade klassningsverktyget CVAT. 11 av dessa stockar saknade synliga spår av törskateinfektion.

Urvalet av bilder för manuell klassning hade målet att få ett urval av bilder:

- med och utan fetved,
- med central respektive perifer fetved, och
- från olika höjder hos varje stock, vilka kan förväntas ha olika diameter och medeldensitet.

För samtliga stockar användes topp- och rotbilden (15 cm från skäret för att inte få med bilder på CT-skannerns fixeringsanordning). För stockar med törskaterelaterade fetvedsområden valdes om möjligt en bild innan och en bild efter varje fetvedsområde, samt 4–6 bilder slumpmässigt men jämnt utspridda över fetvedsområdet. För stockar utan synlig reaktionsved valdes 3–6 bilder slumpmässigt men jämnt utspridda över stocken. Totalt bedömdes 77 av bilderna innehålla fetved och 98 inte innehålla fetved.

Varje bild klassades av tre trämaterialkunniga projektmedlemmar i klasserna kärnved, splintved och fetved (Figur 7). I de fall då kärnveden misstänktes ha kådanrikning till följd av törskateinfektion klassades ändå kärnvedsområdet som kärnved och inte fetved. Kvistar eller delar av kvistar som var lokaliserade till kärnvedsområdet klassades alltid som tillhörande splintved.




Figur 7. Exempel på manuell klassning. Övre höger: originalbild. Bild A: klassning enligt klassande individ A, Bild B: klassning enligt individ B, och Bild C: klassning enligt individ C.

Flera faktorer gjorde klassningen utmanande. För stockar med kraftig törskaterelaterad fetvedsutbredning som helt inneslöt kärnveden var det ofta svårt att bestämma kärnvedens verkliga utbredning. I dessa fall studerades kärnvedens storlek och form i normala delar av samma stock för att underlätta bedömningen. I vissa fall förekom flammiga högdensitetsstråk (ljus gråskalevärde i bilderna) inuti den mer vanligt förekommande lågdensitetsfetveden (mörkt gråskalevärde i bilderna). I vissa av dessa fall var fetveden sannolikt så mättad med kåda att dess densitet är i samma nivå som hos frisk splintved, med andra ord högdensitetsfetved. Dessa oklara områden klassades här som splintved. Det förekom även ljusa stråk mellan vissa fetvedsområden och ytan, där det var oklart om dessa var övervallad frisk splintved eller kådmättad högdensitetsfetved. Dessa områden klassades också som frisk splintved.

Två aspekter av resultatet ska valideras: hur väl algoritmen lyckas bestämma antalet pixlar i varje klass (aritmetisk träffsäkerhet), och hur väl den lyckas bestämma pixlarnas position (spatial träffsäkerhet). Det hade varit idealt med ett valideringsmått som tar tillräcklig hänsyn till båda aspekterna. Eftersom något sådant inte identifierades beräknades i stället två valideringsmått: DICE och SMAPE.

För att validera det spatials överlappet beräknades DICE-indexet för varje set av manuellt respektive automatiskt klassad bild, och respektive klass. DICE-indexet har värden mellan noll och ett, där noll är ingen överensstämmelse och ett är bästa möjliga överensstämmelse. Det definieras som dubbla överlappet mellan två set, i detta fall manuell respektive automatisk klassning, dividerat med deras summa (Figur 8). En nackdel med DICE-indexet är att om den manuellt klassade bilden har noll pixlar i en klass medan den automatiskt klassade har ett fåtal pixlar, får DICE värdet noll trots att den aritmetiska överensstämmelsen är relativt god. En annan nackdel är att klasser med många pixlar, till exempel frisk splintved, lättare får höga DICE-värden jämfört med klasser med färre pixlar.



Figur 8. Definitionen av valideringsindexet DICE: två gånger unionen av den manuella klassningen och algoritmens klassning dividerat med deras summa.

Att validera antalet pixlar i varje klass är analogt med att utvärdera en regressionsmodell. När referenskategori (i detta fall antalet pixlar i den manuellt klassade bilden) ofta får värdet noll är ett lämpligt valideringsmått Symmetric Mean Absolute Percentage, SMAPE, vilket definieras som:

$$SMAPE = \frac{1}{N} \sum_{t=1}^n \frac{|F_t| - |A_t|}{|A_t| + |F_t|} \quad [3]$$


där N är totala antalet pixlar för den givna klassen i alla valideringsbilder, F är prediktionens (algoritmens) antal pixlar för den givna klassen, och A är referensens (den manuella klassningens) antal pixlar för den givna klassen i den manuellt annoterade bilden. Vissa definitioner av SMAPE innehåller en division med två, denna användes inte för att få samma skala som DICE-indexet, det vill säga [0, 1]. För att även få samma

värdestolkning som DICE, det vill säga där noll är sämsta värdet och ett är bästa värdet, användes komplementet till SMAPE:

$$SMAPE_{kompl} = 1 - SMAPE \quad [4]$$

3D-analys (connected components)

För att kunna utvärdera algoritmens förmåga att bestämma längd och masscentrumshöjd hos fetveden behöver enskilda fetvedsområden karaktäriseras. Det gjordes genom en 3D-connected component-analys med Python-paketet dask-image. Resultatet blir ett stort antal indexerade komponenter med storlek från en voxel till hundratusentals voxlar (Figur 9).



Figur 9. Exempel på connected component-analys av fetveden överlagd på algoritmens klassning innan efterbearbetning. Färgerna och siffrorna markerar olika connected components. Stock 6-2, sedd i xy-planet. Övre vänster: höjd z=953 voxlar. Övre mitt: höjd z=4099 voxlar. Övre höger: höjd z=7983 voxlar. Underst: samma stock i xz-planet. De gula strecken visar var i stocken de övriga bilderna är tagna.

För varje komponent extraheras dess volym, masscentrum och utbredning i x, y och z-led (Tabell 2).


Tabell 2. Exempel på resultat från connected component-analys av fetvedskomponenter, sorterat på volym. Komponentens index motsvarar de gula siffrorna i Figur 9. Volymen är fetvedskomponentens procentandel av stockens totala volym.

Index	Volym (voxlar)	Volym (%)	Längd (voxlar)	Masscentrum (voxlar)
102	201 308	3,29	3444	3777
25	8011	0,25	1035	2001
1049	502	0,11	209	589
3	56	0,08	704	1501
388	14	0,02	42	4533


Utmaningen vid validering då komponenter ska matchas av visuellt bedömda mått blir att identifiera rättklassningskandidater. Visuellt bedömning tyder på att fetvedsområden kan ha volym från lägre än en promille av stockvolymen till över 10 procent av stockvolymen. Om komponenterna sorteras efter storlek finns ofta några överklassningskandidater bland de största komponenterna, medan en del underklassningskandidater finns bland de

minsta. Erfarenhetsmässigt är det mindre vanligt att komponenter med volym ≥ 0.1 procent är överklassningskandidater, även om de kan vara rättklassningskandidater med överklassad volym och längd. Därför gjordes två filtreringar av komponenterna:

1. Filtrering av komponenter baserat på komponentvillkoret, det vill säga att deras volym (avrundad uppåt) är lika med eller större än 0.1 % av stockens totala volym.
2. Visuellt matchning av komponenter med ingångshöjd, och manuell selektering av matchande komponent.
3. Två utvärderingar gjordes därefter, illustrerade i Figur 10 och Figur 11.
4. Komponenternas masscentrumshöjd jämfördes med infektionens ingångshöjd, på de stockar där troliga ingångspositioner kunde identifieras.
5. Komponenternas inre längd i höjddled jämfördes med fetvedsområdets inre längd i höjddled mätt visuellt i CT-bilderna (Hyll m.fl. 2022).



Figur 10. Visuellt bedömd infektionsingångshöjd (gul pil) samt visuellt bedömd fetvedslängd (blå pil).



Figur 11. Den algoritmklassade fetvedskomponentens masscentrum (gul cirkel) och längd (blå pil). I praktiken sker bestämningen av dessa mått genom beräkning av begränsningslådor (bounding boxes) runt komponenterna.

Resultat

Träffsäkerhet

Klassning av enskilda bilder

$SMAPE_{kompl}$ -indexet för enskilda bilder visas i Tabell 3, där värdet ett (1) är bästa möjliga överensstämmelse mellan automatisk och manuell klassning, och noll (0) är ingen överensstämmelse.

Tabell 3. Valideringsmättet $SMAPE_{kompl}$ (1-SMAPE) för de tre klasserna kärnved, splintved och fetved baserat på jämförelse av algoritmens resultat utan och med efterbearbetning (EB) med 167 manuellt klassade bilder. ALG = algoritm utan efterbearbetning. EB = algoritm med efterbearbetning. Låga värden är sämre och höga värden är bättre.

$SMAPE_{kompl}$	Kärnved		Splintved		Fetved	
	ALG	ALG + EB	ALG	ALG + EB	ALG	ALG+EB
Klassande person A	0,83	0,86	0,96	0,96	0,55	0,42
Klassande person B	0,85	0,86	0,97	0,97	0,63	0,57
Klassande person C	0,85	0,86	0,97	0,97	0,60	0,53
Medelvärde	0,84	0,86	0,97	0,97	0,58	0,49

Resultatet av valideringsindexet DICE på enskilda bilder visas i Tabell 4, där värdet ett (1) är bästa möjliga överensstämmelse mellan automatisk och manuell klassning, och noll (0) är ingen överensstämmelse.

Tabell 4. Valideringsmättet DICE för de tre klasserna kärnved, splintved och fetved baserat på jämförelse av algoritmens resultat utan respektive med efterbearbetning (EB) med 167 manuellt klassade bilder. ALG = algoritm utan efterbearbetning och EB = algoritm med efterbearbetning. Låga värden är sämre och höga värden är bättre.

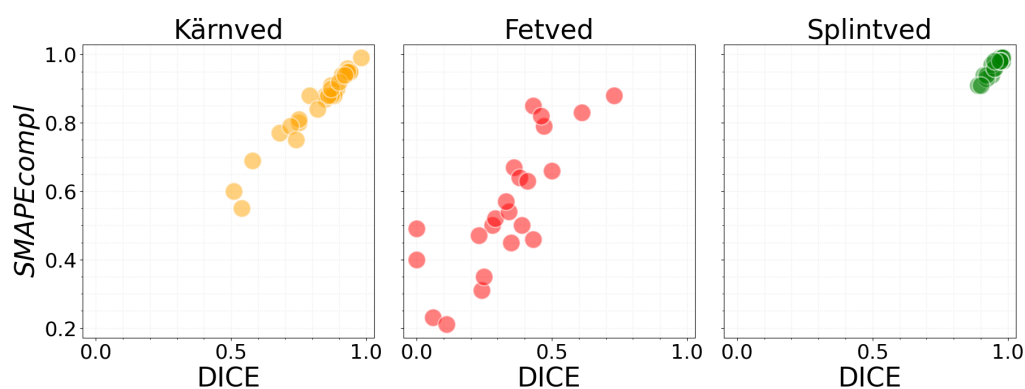
DICE-index	Kärnved		Splintved		Fetved	
	ALG	ALG + EB	ALG	ALG + EB	ALG	ALG+EB
Klassande person A	0,80	0,82	0,94	0,95	0,37	0,38
Klassande person B	0,81	0,83	0,96	0,96	0,44	0,45
Klassande person C	0,80	0,82	0,96	0,96	0,36	0,37
Medelvärde	0,81	0,82	0,95	0,95	0,39	0,40

Medelvärden av genomsnittet av SMAPE och DICE visas i Tabell 5:

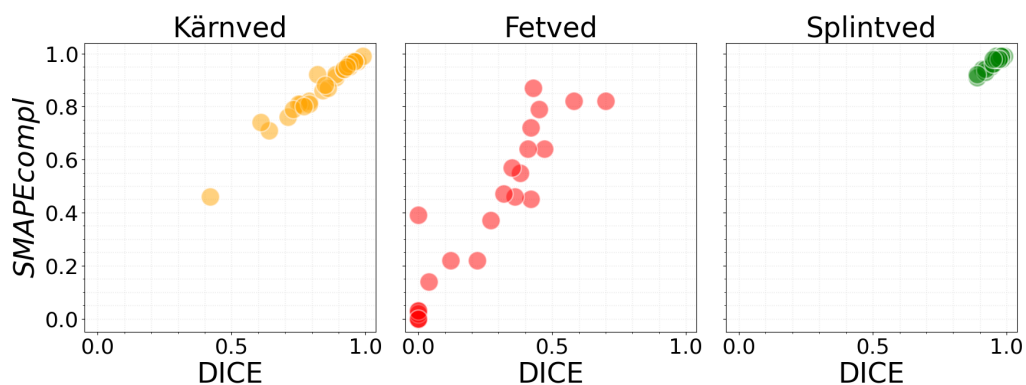
Tabell 5. Medelvärden av valideringsmått för de tre klasserna kärnved, splintved och fetved. ALG = algoritmen utan efterbearbetning. EB = algoritmen med efterbearbetning. Låga värden är sämre och höga värden är bättre.

Vedklass	Metod	Medelvärde
Kärnved	ALG	0,83
	ALG + EB	0,84
Splintved	ALG	0,96
	ALG + EB	0,96
Fetved	ALG	0,49
	ALG + EB	0,45

Generellt tyder index-värden på 0,5 och däröver på att modellen har acceptabel överensstämmelse med manuellt klassade bilder. Modellen får högre värden på SMAPE-indexet, som framför allt mäter hur väl den predikterar antalet pixlar i olika klasser, än för DICE-indexet, som framför allt mäter det hur väl modellen predikterar den rumsliga placeringen av klasserna. Vidare går det att se att efterbearbetningen generellt sett förbättrar resultaten, men inte för fetvedens SMAPE-index. Figur 12 och Figur 13 visar båda valideringsmått utan respektive med efterbearbetningssteget, där varje punkt representerar en stock.



Figur 12. Valideringsmått för enskilda bilder och respektive vedklass, utan efterbearbetningssteget. Varje punkt representerar medelvärdet för en stock.



Figur 13. Valideringsmått för enskilda bilder och respektive vedklass, med efterbearbetningssteget. Varje punkt representerar medelvärdet för en stock.

För båda indexen når splint- och kärnvedklasserna väl över 0,5, medan fetvedsklassen endast gör det för vissa fall. Den sämre prediktionen av fetveden har två anledningar. Det ena är att DICE-värdet blir noll om den manuella klassningen inte har någon fetved medan algoritmens resultat har det, även om det bara är en enda pixel i algoritmens klassning som är fetved. Att algoritmens klassning har en försumbart liten mängd fetved medan den manuella klassningen inte har identifierat någon fetved förekommer i flera fall. Den andra är att algoritmen misslyckats med klassningen av några stockar vilket drar ner helhetsresultatet signifikant.

Sammanfattningsvis visar resultatet att det finns goda möjligheter att justera algoritmen för fetved, till exempel utesluta mycket små områden detekterad fetved, så att överensstämmelse med automatisk detektering och manuell detektering blir betydligt bättre.

Klassning av hela stockar

Andelen rättklassade stockar med de olika algoritmalternativen och villkoren visas i Tabell 6. Data redovisas även i Tabell A1 i Appendix.

Tabell 6. Procentandelen rättklassade stockar (fetvesstock eller normalstock) med de olika algoritmalternativen (utan och med efterbearbetning, EB) och villkoren. Totalvillkor innebär att en stock klassas som fetvedsstock om totala volymen fetved är ≥ 1 %. Komponentvillkoret innebär att en stock klassas som fetvedsstock om minst en fetvedskomponent har volym $\geq 0,1$ %. Visuellt bedömning av CT-bilderna utgör referens.

Andel rättklassade stockar (%)	Totalvillkor	Komponentvillkor
Algoritm	78	56
Algoritm + EB	89	83

Algoritmens utfall avseende under- eller överdetektering av fetved redovisas antalsbaserat i Tabell 7 till

Tabell 10.

Tabell 7. Antalet klassade fetvedsstockar respektive normalstockar baserat på visuellt bedömning respektive algoritm, där totalvillkor använts för att klassa stockarna i normalstockar respektive fetvedsstockar (total skadevolym ska vara ≥ 1 % för att stocken ska räknas som fetvedsstock).

Basalalgoritm, totalvillkor (%)	Fetvedsstock (algoritm)	Normalstock (algoritm)
Fetvedsstock (visuellt)	44	8
Normalstock (visuellt)	14	33

Tabell 8. Antalet klassade fetvedsstockar respektive normalstockar baserat på visuellt bedömning respektive algoritm, där komponentvillkor använts för att klassa stockarna i normalstockar respektive fetvedsstockar (minst en komponent måste ha volym $\geq 0,1$ % för att stocken ska räknas som fetvedsstock).

Basalalgoritm, komponentvillkor (%)	Fetvedsstock (algoritm)	Normalstock (algoritm)
Fetvedsstock (visuellt)	53	0
Normalstock, visuellt	44	3

Tabell 9. Antalet klassade fetvedsstockar respektive normalstockar baserat på visuellt bedömning respektive algoritm + efterbearbetning (EB), där totalvillkor använts för att klassa stockarna i normalstockar respektive fetvedsstockar (total skadevolym ska vara ≥ 1 % för att stocken ska räknas som fetvedsstock).

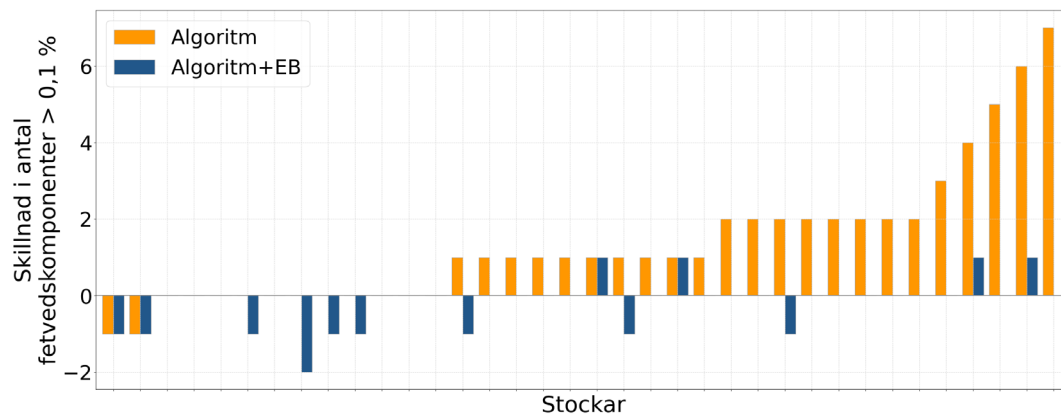
Algoritm + EB, totalvillkor (%)	Fetvedsstock (algoritm)	Normalstock (algoritm)
Fetvedsstock (visuellt)	42	11
Normalstock (visuellt)	0	47

Tabell 10. Antalet klassade fetvedsstockar respektive normalstockar baserat på visuell bedömning respektive algorit + efterbearbetning (EB), där komponentvillkor använts för att klassa stockarna i normalstockar respektive fetvedsstockar (minst en komponent måste ha volym $\geq 0,1$ % för att stocken ska räknas som fetvedsstock).

Algoritm + EB, komponentvillkor (%)	Fetvedsstock (algoritm)	Normalstock (algoritm)
Fetvedsstock (visuell)	47	6
Normalstock (visuellt)	11	36

Resultaten visar att basalgoritmen överklassar och underklassar stockar i ungefär samma utsträckning. Med andra ord kommer en del normalstockar att klassas som fetvedsstockar. Efterbearbetningssteget gör att vissa skador missas, men att färre normalstockar klassas som fetvedsstockar. Det kan även noteras att efterbearbetningssteget får större genomslag vid klassningen av hela stockar jämfört med för enskilda bilder. En möjlig förklaring är att samtliga 36 stockar användes vid valideringen på stocknivå, medan 28 användes vid valideringen på enskilda bilder. Flertalet av de stockar som inte användes på tvärsnittsnivå saknade synliga spår av törskateinfektion, och det är just den typen av stockar där efterbearbetningen gör störst skillnad.

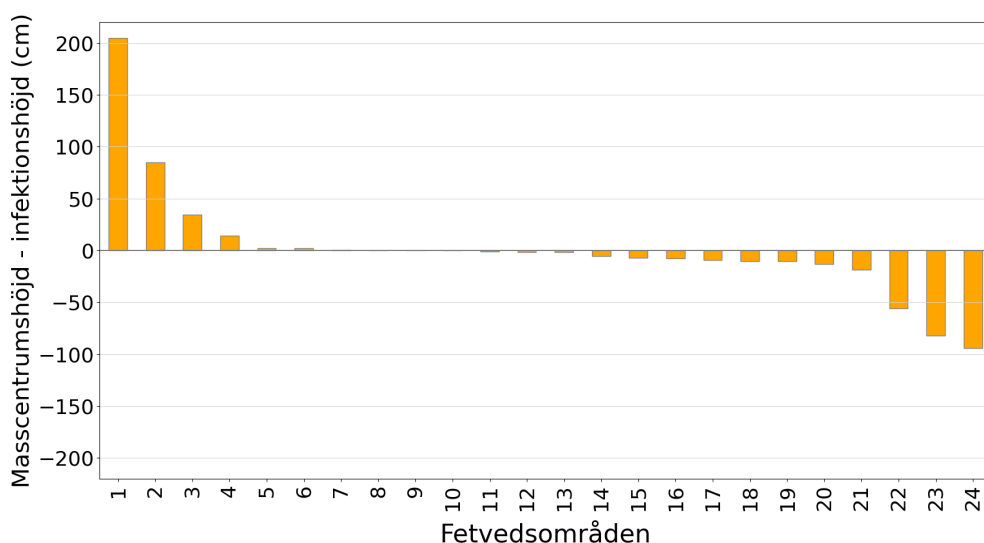
Mätning av exakt antal fetvedsområden i en fetvedsstock är en större utmaning. Komponentvillkoret behövs för att filtrera fram rättklassningskandidater, men rättklassningskandidater kan ha mindre volym än villkoret och överklassningskandidater kan vara större. Basalgoritmen bestämde korrekt antalet fetvedsområden i 31 % av stockarna, medan procentandelen var 64 % om efterbearbetningssteget tillämpades. Basalgoritmen överskattar antalet fetvedsområden medan efterbearbetningssteget underskattar (Figur 14).



Figur 14. Antal fetvedsområden som uppfyller komponentvillkoret (volym $\geq 0,1$ %) jämfört med antalet visuellt identifierade fetvedsområden i samma stock.

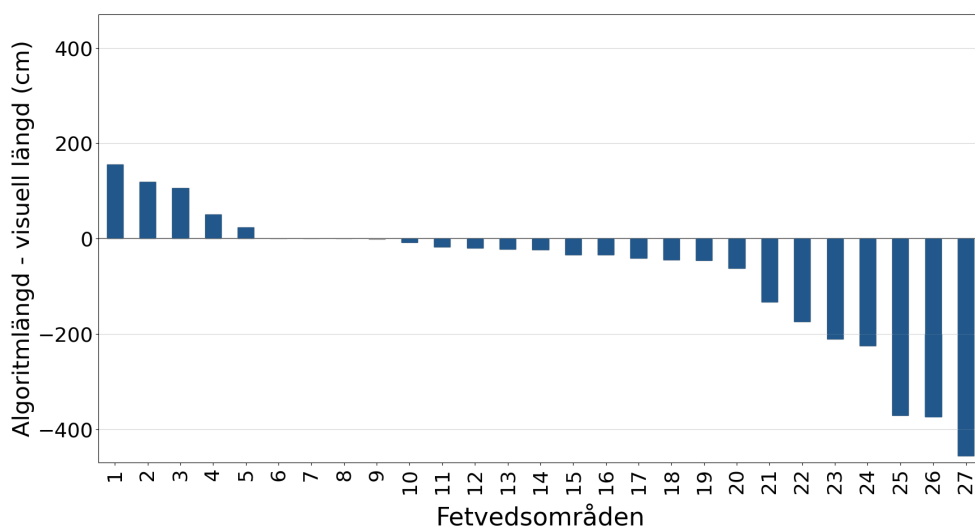
Infektionsingångshöjd vs. masscentrumshöjd

Överensstämmelsen mellan fetvedskomponenten masscentrumshöjd och den visuellt bedömda ingångshöjden för törskateinfektionen visas i Figur 15. Data redovisas även i Tabell A2 i Appendix. Den genomsnittliga skillnaden var 1 cm och den genomsnittliga absoluta skillnaden 28 cm.



Figur 15. Skillnaden i masscentrumshöjd hos fetvedskomponenter såsom given av algoritmen och matchande visuellt bedömd ingångshöjd för törskateinfektionen. För tre visuella fetvedsområden kunde inte höjden matchas då algoritmen klassat dem som sammanhängande med en annan fetvedskomponent.

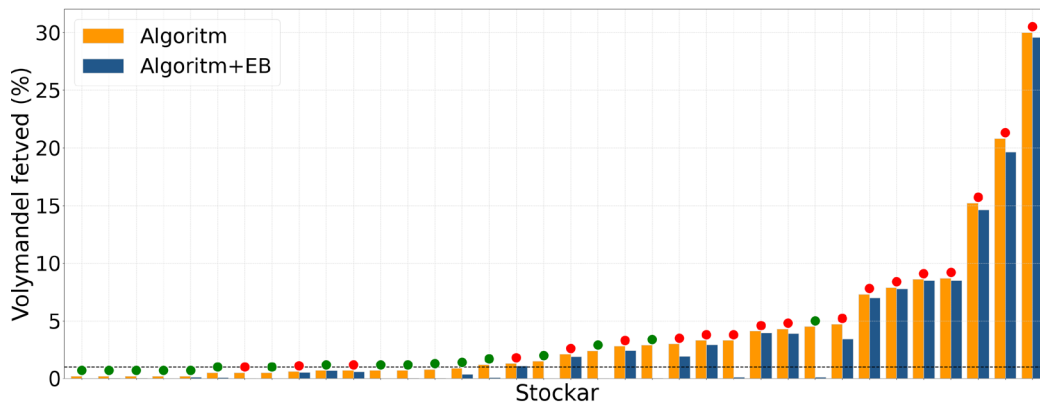
Överensstämmelsen mellan komponentlängden och den visuellt bedömda längden visas i Figur 16. Den genomsnittliga skillnaden var -68cm, det vill säga algoritmen tenderar att underskatta längden, medan den genomsnittliga absolutskillnaden var 148 cm.



Figur 16. Skillnaden i längd hos fetvedskomponenter såsom given av algoritmen och matchande visuellt bedömd längd. För tre visuella fetvedsområden kunde inte längden matchas då algoritmen klassat dem som sammanhängande med en annan fetvedskomponent.

Volymandel fetved

De stockar som vid visuell bedömning ansetts ha fetved har enligt algoritmen en genomsnittlig fetvedsvolym på 6,8 %, eller 6,2 % om efterbearbetningssteget tillämpas. De stockar som visuellt ansetts vara fetvedsfria har enligt algoritmen en genomsnittlig fetvedsandel på 1,1 %, eller 0,1 % om efterbearbetningssteget tillämpas. Volymandelen detekterad fetved hos stockar både med och utan visuell fetved visas i Figur 17.



Figur 17. Totalandel fetved (% av stockens volym) enligt basalgoritmen respektive algoritmen inklusive efterbearbetningssteget (EB). Totalvillkoret för att stocken ska klassas som fetvedsstock visas som en svart streckad linje. En röd prick ovanför stapeln innebär att stocken visuellt ansetts ha fetved, medan en grön prick innebär att den visuellt bedömts vara en normalstock.

Effektivitet och processeringshastighet

För industriell tillämpning är exekveringstiden hos ett program eller en algoritm ofta kritisk. Utvärdering av körtider gör att koden kan optimeras för tillgängliga datorresurser, samt låter en säkerställa att prestandakraven som finns för tillämpningen verkligen uppfylls. Internt har arbetsgruppen använt programspråket Python för att implementera merparten av segmenteringen och övriga nödvändiga funktioner, exempelvis inläsning av bilddata. Vissa delar av segmenteringen visade sig vara så pass beräkningsintensiv att C++ i stället fick användas för att snabba upp processtiden; i detta fall kompilerades C++-koden till ett bibliotek som sen dynamiskt laddades in via Python-koden.

Exempel på en logg av körningstiden för en segmentering visas i Figur 18.

```
INFO:wood_segmentation:Reading input image /log_5-1_2729_rsdn16.tiff...
INFO:wood_segmentation:Done. Time elapsed: 0.007991 s
INFO:wood_segmentation:Applying Gaussian smoothing to input image...
INFO:wood_segmentation:Done. Time elapsed: 0.005404 s
INFO:wood_segmentation:Computing heatmap for heartwood...
INFO:wood_segmentation:Done. Time elapsed: 0.268162 s
INFO:wood_segmentation:Applying Gaussian smoothing to heatmap...
INFO:wood_segmentation:Done. Time elapsed: 0.003465 s
INFO:wood_segmentation:Generating label mask for segmentation...
INFO:wood_segmentation:Done. Time elapsed: 0.082403 s
python segmentation.py CT-1/log_5-1/Denoised 3085.49s user 21.08s system 910% cpu 5:41.13
```

Figur 18. Logginformationen visar att algoritmen tog 5 minuter och 41 sekunder för stock 5-1, vars stack innehöll 7557 bildtvärsnitt. Varje steg i algoritmen tar olika tid, exempelvis tar det Guassianska filtret 0.007 sekunder, och 2D-connected component-analysen 0.08 sekunder.

Diskussion

Noggrannhet och träffsäkerhet

Antalet törskaterelaterade fetvedsområden

När totalvillkoret (totalvillkor innebär att en stock klassas som fetvedsstock om totala volymen fetved är ≥ 1 %) användes för att klassa stockar som fetvedsstock eller normalstock felklassades sex eller åtta stockar, beroende på om efterbearbetningssteget tillämpades eller inte. Vissa felklassningar är lätta att förstå. Till exempel hade stock 10-1 ett mycket litet fetvedsområde nära mantelytan som upptäcks av algoritmen, men vars volym varken uppfyllde totalvillkoret eller komponentvillkoret, och klassades därmed inte som fetved vid den manuella detekteringen som genomfördes av tre referensindivider.

När komponentvillkoret (komponentvillkoret innebär att en stock klassas som fetvedsstock om minst en fetvedskomponent har volym $\geq 0,1$ %) används felklassas betydligt fler stockar. Komponentvillkorets tröskelvärde är dock möjligt att ändra. Stock 6-2 hade räknats som fetvedsstock om komponentvillkoret var 0,01 % av volymen istället för 0,1 %. Samtidigt gav inget annat tröskelvärde bättre övergripande resultat. Komponentvillkoret kan också vara missvisande. Stock 8-3 räknades som fetvedsstock, vilket stämde, men det berodde på tre stora överklassningskandidater, medan rättklassningskandidaten var betydligt mindre än både totalvillkoret och komponentvillkoret.


Sammantaget kan enskilda komponenters storlek inte ensamt avgöra vad som är rättklassningskandidater. För att förstå varför antalet komponenter, komponentlängderna och deras masshöjdscentrum skiljer sig från referensen behövs en genomgång av orsaker till felklassning.

Överklassning av fetved

Resultaten indikerar att algoritmen innan efterbearbetningssteget är översensitiv, det vill säga den klassar fetved som sannolikt inte finns. Det leder till överskattning av fetvedskomponenternas volym och längd, till dålig matchning av komponenternas masscentrumshöjd och infektionens ingångshöjd, samt till otillfredsställande DICE-värde. Det finns sex typiska orsaker till överklassningskandidater:


1. kvistar,
2. breda lågdensitetsårsringar,
3. kärnvedsangränsande fetved,
4. kådanrikad kärnved,
5. bark klassad som fetved, det vill säga ytnära överklassning, samt
6. högdensitetskärnved.

Centralområden hos kvistar (kvistcentra) klassas som fetved på grund av densitet i samma nivå som fetved. Dessa överklassade kvistcentra har vanligen liten betydelse då kvistar är små, men undantag finns. Stock 7-2 har exempelvis större felklassade kvistar (Figur 19), varav en skapar en stor sammanhängande komponent med kärnvedsanknuten överklassad fetved, med volym överstigande 0,1 % av stockvolymen.




Figur 19. Exempel på överklassningskandidater till följd av kvistar. Från stock 7-2, med ett synligt fetvedsområde. Tvärsnitt från höjd $z=579$ voxlar. Övre vänster: originalbild. Övre mitt: algoritmens klassning, där kärnvedsklassen är ljusgrå, fetvedsklassen mellangrå, och splintvedsklassen mörkgrå. De gula pilarna visar kvistar, dvs klassade som fetved. Övre höger: som mittbilderna, men med efterbearbetning samt med färgläggning enligt connected component-analys. Nederst: som övre höger, men sedd i xz-planet. Det gula strecket visar var i stocken exemplet är lokaliserat.

Breda årsringar med låg densitet kan felklassas som fetved till följd av sin liknande densitet. De kan ha lång utbredning i stockens höjddled, vilket leder till en signifikant överklassad fetvedsvolym. I de fall lågdensitetsårsringarna ligger nära kärnveden omklassas de av efterbehandlingssteget, men inte när de ligger längre ut i splintveden. Ett exempel visas i Figur 20.



Figur 20. Exempel på överklassningskandidater till följd av breda årsringar med låg densitet (gula pilar). Från stock 8-3, med ett synligt fetvedsområde. Tvärsnitt från höjd $z=1990$ voxlar. Övre vänster: originalbild. Övre mitt: algoritmens klassning, där kärnvedsklassen är ljusgrå, fetvedsklassen mellangrå, och splintvedsklassen mörkgrå, dvs felklassning av vissa årsringar. Övre höger: som Övre mitt, men med efterbearbetning. De gula pilarna visar felklassningskandidater som motsvarar årsringar. Nederst: algoritmens klassning i xz-planet, där det gula strecket visar var i stocken exemplet är lokaliserat.


Ett exempel på en kärnvedsangränsande överklassningskandidat visas i Figur 21. Denna överklassning är mycket vanlig och beror sannolikt på skiftningen i densitet i övergången mellan kärnved och splintved på grund av förändring av vedens vatteninnehåll. Efterbearbetningssteget omklassar dessa överklassningskandidater till kärnved i stockar utan ytnära rättklassningskandidater. Hos de stockar som har ytnära rättklassningskandidater men också kärnvedsangränsande överklassningskandidater har efterbearbetningssteget ingen effekt. Det gäller exempelvis stockarna 1-1, 9-1 och 9-2.




Figur 21. Exempel på överklassningskandidater till följd av kärnvedsangränsning. Stock 1-1, med ett synligt fetvedsområde. Tvärsnitt från höjd $z=5212$ voxlar. Övre vänster: originalbild (en skanningsartefakt kan anas). Övre mitt: algoritmens klassning, där kärnvedsklassen är ljusgrå, fetvedsklassen mellangrå, och splintvedsklassen mörkgrå. Övre höger: som Övre mitt, men med efterbearbetning samt med färgläggning enligt connected component-analys. Nederst: som Övre mitt, men sedd i xz-planet. Det gula strecket visar var i stocken exemplet är lokaliserat.

Ett annat exempel visas i Figur 22, där kärnvedsnära överklassning leder till att fetvedsvolymen blir ett mycket stort, sammanhängande fetvedsområde i connected component-analysen i stället för två medelstora fetvedsområden.

Ett till exempel på törskatepåverkad kärnved och kärnvedsnära överklassning visas i Figur 23. Här har kärnveden ökat i densitet till följd av kådinlagringen, vilket förvirrar algoritmen. Algoritmen förstår heller inte att kärnveden alltid finns i anslutning till mårgen. Detta leder till en mycket stor överklassning av fetvedsvolymen och en underklassning av kärnvedsvolymen.




Figur 22. Exempel på överklassningskandidat till följd av kärnvedsangränsning. Stock 6-2 med två synliga fetvedsområden. Tvärsnitt från höjd $z=2452$ voxlar. Övre vänster: originalbild. Övre mitt: algoritmens klassning, där kärnvedsklassen är ljusgrå, splintvedsklassen mörkgrå. Övre höger: efterbearbetning, med connected-component-analysens färgkodning. Symbol A markerar starten av fetvedsområde #1, medan symbol B markerar en perifer del av fetvedsområde #2. Underst: som Övre höger, men sedd i xz-planet. Det gröna strecket visar var i stocken exemplet är lokaliserat.




Figur 23. Exempel på överklassningskandidater till följd av törskatepåverkad kärnved och kärnvedsankytning. Från stock 9-2 med två synliga fetvedsområden. Tvärsnitt från höjd $z=6215$ voxlar. Övre vänster: originalbild. Övre mitt: algoritmens klassning, där kärnvedsklassen är ljusgrå, splintvedsklassen mörkgrå och fetvedsklassen gul. Den gula cirkeln indikerar kärnvedens troliga utbredning. Övre höger: med efterbearbetning, där färgen är ett lager från connected component-analysen. Nederst: som Övre höger, men sedd i xz-planet. Symbolen A markerar starten av fetvedsområde #1, medan symbol B markerar fetvedsområde #2. Det gröna strecket visar var i stocken exemplet är lokaliserat.

Ett exempel på ytnära överklassningskandidater visas i Figur 24. Det är relativt ovanligt och tycks inte vara relaterat till bark, då algoritmen oftast hanterar bark väl. Fenomenet uppstår oftast högt upp i tredjestocken, vilket gör det troligt att det har med stocktvärsnittets eller kärnvedens diameter att göra. Om denna felklassning väl ägt rum kan den inte åtgärdas med efterbearbetningssteget, då ytnära komponenter inte påverkas



Figur 24. Exempel på överklassningskandidater relaterade till bark eller smal stock. Från stock 4-3, utan synliga fetvedsområden. Tvärsnitt från höjd $z=810$ voxlar. Övre vänster: originalbild. Övre mitt: algoritmens klassning, där kärnvedsklassen är ljusgrå, splintvedsklassen mörkgrå och fetvedsklassen ljusgrå. Övre höger: med efterbearbetning, där färgen är ett lager från connected component-analysen. Nederst: som Övre höger, men sedd i xz -planet. Det gula strecket visar var i stocken exemplet är lokaliserat.




Figur 25. Exempel på överklassningskandidater relaterade till bark eller smal stock. Från stock 2-3, utan synliga fetvedsområden. Tvärsnitt från höjd $z=415$ voxlar. Övre vänster: originalbild. Övre mitt: algoritmens klassning, där kärnvedsklassen är ljusgrå, splintvedsklassen mörkgrå och fetvedsklassen ljusgrå. Övre höger: med efterbearbetning, där färgen är ett lager från connected component-analysen. Nederste: som Övre höger, men sedd i xz -planet. Det gula strecket visar var i stocken exemplet är lokaliserat.

Underdetektering av fetved

Följande underklassningsorsaker leder till underskattning av mängden fetved och av fetvedskomponenternas längd och volym, till dålig matchning av komponenternas masscentrumshöjd och infektionens ingångshöjd, samt till otillfredsställande DICE-värde:


1. högdensitetsfetved,
2. breda fetveds-sommarvedsårsringar,
3. kantzon mot mantelytan,
4. överklassning av kärnved,
5. erodering av perifer fetved, och
6. omklassning av fetved med start i föregående stock.

Ett exempel på underdetektering av fetved till följd av högdensitetsfetved visas i Figur 26. Sannolikt beror högdensitetsfetveden på extrem kådinlagring, och den höga densiteten gör att algoritmen klassar den som splintved. Enbart mycket skadade stockar får högdensitetsfetved, vilket gör att stocken kommer identifieras som fetvedsstock även med denna underklassning av fetveden.




Figur 26. Exempel på underklassningskandidat till följd av högdensitetsfetved. Från stock 2-2, med ett synligt fetvedsområde. Tvärsnitt från höjd $z=3180$ voxlar. Övre vänster: originalbild. Övre mitt: algoritmens klassning, där kärnvedsklassen är ljusgrå, splintvedsklassen mörkgrå och fetvedsklassen ljusgrå. De gula pilarna indikerar högdensitetsfetved. Övre höger: efter efterbearbetning, där färgen är ett lager från connected component-analysen. Nederst: som Övre höger, men sedd i xz-planet. Det gula strecket visar var i stocken exemplet är lokaliserat.

Underklassning av breda fetveds-sommarvedsårsringar beror på att algoritmen i huvudsak är känslig för den låga densiteten som sommarved får när den förvandlas till fetved. Vårveden, som hos frisk splintved har lägre densitet än hos sommarved, får hos fetved i stället en högre densitet relativt sommarveden. Algoritmen detekterar sommarveden och länkar sedan ihop sommarvedsårsringarna med morfologisk dilatering. Om årsringarna är breda blir dilateringen otillräcklig, vilket leder till en underskattning av skadan. Det leder dock inte till att fetvedsförekomst missas helt. Figur 27 visar underklassning av breda fetvedssommarringar och kantzon mot mantelytan. Fetvedsöverskattningen till följd av kärnvedanknytning är dock mycket större än underskattningen till följd av de två andra effekterna.



Figur 27. Exempel på underklassningskandidat till följd av breda fetveds-sommarvedsårsringar. Från stock 2-1, med två synliga fetvedsområden. Tvärsnitt från höjd $z=6225$ voxlar. Övre vänster: originalbild. Övre mitt: algoritmens klassning, där kärnvedsklassen är ljusgrå, splintvedsklassen mörkgrå och fetvedsklassen ljusgrå. De gula pilarna indikerar breda fetvedssommarringar. Övre höger: efter efterbearbetning, där färgen är ett lager från connected component-analysen. Nederst: som Övre höger, men sedd i xz-planet. Det gula strecket visar var i stocken exemplet är lokaliserat.

Överklassning av kärnved är relativt ovanligt, men ett exempel visas i Figur 28.




Figur 28. Exempel på underklassningskandidat till följd av överklassning av kärnved. Från stock 2-2, med två synliga fetvedsområden. Tvärsnitt från höjd $z=5622$ voxlar. Övre vänster: originalbild. Övre mitt: algoritmens klassning, där kärnvedsklassen är ljusgrå, splintvedsklassen mörkgrå och fetvedsklassen ljusgrå. Övre höger: med efterbearbetning, där färgen är ett lager från connected component-analysen. Nederst: som Övre höger, men sedd i xz-planet. Det gula strecket visar var i stocken exemplet är lokaliserat.

Om den perifera fetveden är tillräckligt liten riskerar den att eroderas bort av algoritmen, vilket exemplifieras i Figur 29. Det borde ha relativt liten praktisk påverkan i ett sågverk. I denna studie kan det dock få stor påverkan för valideringen av komponenternas längd, då det kan splittra upp en lång komponent i flera korta.



Figur 29. Exempel på underklassningskandidat till följd av erodering av perifer fetved. Från stock 2-3, med ett synligt fetvedsområde. Tvärsnitt från höjd $z=4760$ voxlar (rotskäret). Övre vänster: originalbild, där den gula pilen visar perifer fetved med ingång i föregående stock. Övre mitt: algoritmens klassning, där kärnvedsklassen är ljusgrå, splintvedsklassen mörkgrå och fetvedsklassen ljusgrå. Övre höger: med efterbearbetning.

Stockarna som ligger till grund för den här studien är kapade så att ingångspositionen för infektionen om möjligt hamnar mitt i stocken. Det förekommer dock perifer fetved från infektionsingångar i angränsande stockar. I en verklig sågverkssituation torde detta vara ännu vanligare. Fetved med start i föregående stock och som inte är ytnära riskerar också att omklassas av efterbearbetningssteget (Figur 30). Detta kan leda till en måttlig underklassning av fetveden.



Figur 30. Exempel på underklassningskandidat till följd av omklassning av fetved med ingång i föregående stock. Från stock 10-3, med ett synligt fetvedsområde. Tvärsnitt från höjd $z=5679$ voxlar (rotskäret). Övre vänster: originalbild. Övre mitt: algoritmens klassning, där kärnvedsklassen är ljusgrå, splintvedsklassen mörkgrå och fetvedsklassen färgkodad efter connected component-analysen. Övre höger: med efterbearbetning. Nederst: som Övre mitt, men sedd i xz -planet. Det gröna strecket visar var i stocken exemplet är lokaliserat.

Fetvedsområdets masscentrumshöjd och längd

Sammantaget är de vanligaste orsakerna till feldetekterad masscentrumshöjd kärnvedsangränsande överklassningskandidater, som när de blir tillräckligt stora leder till att komponenternas masscentra förskjuts, samt stora överklassningskandidater. Hos stock 7-1 hittar algoritmen rätt komponent som matchar det yttre såret, men komponenten hänger samman med en stor överklassningskandidat vilket gör att masscentrumshöjden förskjuts. I andra fall är det svårt att matcha en

rättklassningskandidat eftersom överklassningskandidater blir större eller om rättklassningskandidaten är liten. Ett exempel är stock 9-2, där masscentrum hos den tredje största enskilda komponenten ingångshöjden matchar den ena av stockens två yttre skador väl (9 cm skillnad i masscentrumshöjd - ingångshöjd), men rättklassningskandidaten inte uppfyller det komponentvillkoret. För stockarna 2-2 och 3-2 är orsaken till den stora skillnaden mellan masscentrumshöjd och ingångshöjd underdetektering till följd av högdensitetsfetved, vilket gör att volymen skada underskattas där stocken är som mest skadad.

Kärnvedsangränsande överklassningskandidater är även den vanligaste orsaken till överskattad längd. Underskattad längd beror främst på erodering av perifera rättklassningskandidater, vilket leder till att en lång komponent delas upp i flera små.

Kådanrikad kärnved

Det är vanligt att algoritmen klassar kärnved som fetved innanför kärnvedens förväntade utbredningsområde. Det är i dagsläget oklart om törskateinfektionen kan skapa fetved inuti kärnveden. Observationer tyder på det, med den primära effekten att kärnvedens sommarved ökar i densitet. Dock blir skillnaden från normal kärnved generellt sett liten, och det är oklart om det ger någon skillnad i kärnvedens mekaniska egenskaper.

Fetved med hög densitet

I de flesta fall leder törskateinfektionen till att kåda lagras in i sommarveden, som ökar i densitet, medan vårveden tappar vatten och minskar i densitet. Fetved har med andra ord motsatt densitetsförhållande i rätt tillstånd mellan vår- och sommarved jämfört med frisk splintved. Observationer tyder på att allvarlig törskateinfektion kan leda till kådanrikning även i vårveden, vilket gör att fetveden som helhet får en densitet som påminner om splintved. Dessa områden underdetekterades av algoritmen, och bör eventuellt behandlas som en egen klass framöver.

Användbarhet i sågverk

Algoritmen har en relativt hög träffsäkerhet men för användbarhet i sågverk skulle dels träffsäkerheten behöva öka ytterligare, dels skulle överdetekteringen behöva minska. Fetved till följd av törskateinfektion är idag en ovanlig defekt, åtminstone bland de stockar som kommer till sågverken. Antag att 1/1000 av stockarna som mäts in vore fetvedsstockar. Om algoritmen felaktigt skulle klassa fem procent av stockarna som fetvedsstockar så skulle den "hitta" 50 falska fetvedsstockar för varje sann fetvedsstock. För ovanliga defekter är överdetektering med andra ord ett stort problem, och den måste vara låg för att exempelvis ligga till grund för ersättningsgrundande betalning. Algoritmen är heller inte tillräckligt snabb för att klara ett modernt sågverks produktionshastighet.

Därför är nästa utvecklingssteg att utveckla en maskininlärningsalgoritm, lämpligen baserat på neurala nätverk, som både förväntas vara snabbare och bättre kunna ta hänsyn till stockens formparametrar.

Slutsats och resultatsammandrag

Målsättningen med denna studie var att ta fram en automatiserad metod för att detektera och kvantifiera reaktionsved till följd av törskateangrepp på svensk tall. Slutsatsen är att den framtagna algoritmen för att detektera fetved, i första hand orsakad av törskateangrepp, är användbar för att klassa stockar i fetvedsstockar respektive normalstockar med en till i praktiken godtagbar noggrannhet. Den laboratoriebaserade algoritmen är dock ännu för långsam för industriell tillämpning. Därför är nästa utvecklingssteg att utveckla en maskininlärningsalgoritm, lämpligen baserat på neurala nätverk, som både förväntas vara snabbare och bättre kunna ta hänsyn till stockens form.

Resultaten i huvuddrag utifrån studiens är:

- På stocknivå rättklassar algoritmen 58–78 % av stockarna utan att ett så kallat efterbearbetningssteg används, och 83–89 % då efterbearbetningssteget används.
- I bilder av stockens tvärsnitt är algoritmens träffsäkerhet enligt valideringsindexet DICE för de tre klasserna kärnved, splintved och fetved 82 %, 95 % respektive 40 %.
- Algoritmen överdetekterar mängden fetved, huvudsakligen genom att sammanblanda kärnvedens kant med fetved samt genom att klassa vissa mörka årsringar som fetved. Detta leder till att den algoritmdetekterade volymen och längden hos fetveden överskattas.
- Viss underdetektering av fetved förekommer också, dels vid mycket kraftig fetvedsbildning där kådvedsdensiteten blir lika hög som splintvedsdensiteten för rätt trä, dels då små, perifera fetvedsområden trösklas bort på grund av deras begränsade utbredning.
- Den masscentrumshöjd som algoritmen ger för varje fetvedskomponent går att använda för att ge kandidater till den höjd där törskateinfektionen bedöms ha gått in i trädet.
- Den av algoritmen givna längden av fetvedens utbredning i trädstammens/stockens längdriktning överensstämmer dåligt med den visuellt bedömda längden, vilket beror på en kombination av tidigare nämnda feldetekteringsfaktorer.
- Ett efterbearbetningssteg baserat på fetvedens typiska rumsliga utbredning kan användas för att förbättra klassningen, särskilt för stockar som saknar yttre tecken på törskateangrepp.
- Vidareutveckling av algoritmen kan gå mot fler eller färre klasser. Barken bör potentiellt klassas som en separat klass då den har liknande densitet som fetveden. Även fetved med mycket hög högdensitet bör eventuellt ha en egen klass. Alternativt kan en binär klassning göras med bara fetved och icke-fetved som alternativ.
- Ytterligare parametrar relevanta för att klassa fetved förväntas vara märgdetektion, avstånd mellan märgen och fetvedsområdet, samt mellan mantelytan och fetvedsområdet. Dessa parametrar kan inkluderas i en utvecklad maskininlärningsalgoritm.

Referenser

- Adolfsson, H. 2022. Förekomst av törskate (*Cronartium pini*) i tallungskog i norra Sverige: En studie av törskates utbredning och eventuella faktorer som påverkar förekomst. B.Sc. thesis, Umeå University, s.
- Eriksson, H., Bergqvist, J., Hazell, P., Isacsson, G., Lomander, A. & Black-Samuelsson, S. 2016. Effekter av klimatförändringar på skogen och behov av anpassning i skogsbruket. Skogsstyrelsen. s.
- Fredriksson, E., Fahlvik, N., Öhlund, J. & Svennerstam, H. 2023. Produktionsnedsättning i törskateangripen gallringsskog. Arbetsrapport 1163-2023, Skogforsk. 31 s.
- Gramner, T. & Jernberg, B. 2022. Satellitbilder avslöjar: ju längre norrut desto sämre ungsogar. Skogsstyrelsen. URL: <https://via.tt.se/pressmeddelande/satellitbilder-avslojar-ju-langre-norrut-desto-samre-ungskogar?publisherId=415163&releaseId=3319676> [Hämtad 2022-04-20].
- Gross, M. & Pfister, H. 2007. Point-Based Graphics, Morgan Kaufmann, s.
- Hyll, K., Joevenllyer, S., Svennerstam, H., Nordström, M., Broman, O., Oja, J. & Sandberg, D. 2022. CT-skanning som verktyg för detektering av törskateangrepp på tall. Skogforsk Arbetsrapport 1126-2022. 1-37 s.
- JMMI 2012. Jord- och skogsbruksministeriets beredskapsplan för skogsskador. Jord- och skogsbruksministeriet. 24 p. s.
- Kaitera, J., Aalto, T. & Jalkanen, R. 1994. Effect of resin-top disease caused by *Peridermium pini* on the volume and value of *Pinus sylvestris* saw timber and pulpwood. *Scandinavian Journal of Forest Research*, 9, 376-381.
- Kim, M.-S., Hantula, J., Kaitera, J., Zambino, P. J., Woodward, S., Richardson, B. A., Stewart, J. E., Spaine, P., Shaw, D. C., Takeuchi, Y. & Klopfenstein, N. B. 2022. Recovery Plan for Scots Pine Blister Rust Caused by *Cronartium pini*. *Plant Health Progress* 2022, 23, 105-130.
- Metla. 2007. Several plant species in Finland support rapid spread of *cronartium* rust and white-pine blister rust, URL. Metla. URL: <http://www.metla.fi/tiedotteet/2007/2007-02-07-tervasroso-en.htm> [Hämtad 2022-04-10].
- Samils, B. & Stenlid, J. 2022. A review of biology, epidemiology and management of *Cronartium pini* with emphasis on Northern Europe. *Scandinavian Journal of Forest Research*, 37, 153-171.
- Stenlid, J. 2021. Törskate i multiskadade skogar i norr. Department of Forest Mycology and Plant Pathology. 17 p. s.

Appendix

Tabell A1. Stora fetvedskomponenter och deras andel av stockens totala volym såsom detekterad av algoritmen och beräknad genom connected component-analys. ALG: Algoritmens klassning. ALG+EB: algoritmens klassning följt av efterbearbetning. KV: komponentvillkor. TV: totalvillkor. Blå fyllning innebär att algoritmen underdetekterade, medan röd fyllning att den överdetekterade.

Stam-stock	Visuellt	Antal skador KV		Skada TV		Volym fetved (%)		Kommentar
	Antal skador	ALG	ALG+EB	ALG	ALG+EB	ALG	ALG+EB	Orsaker
1-1	1	1	1	1	1	4,1	4,00	
1-2	2	3	2	1	1	7,9	7,80	Sammanhäng
1-3	2	2	2	1	1	2,1	1,90	
2-1	2	1	1	1	1	15,2	14,60	Sammanhäng
2-2	1	1	1	1	1	8,7	8,50	
2-3	1	1	1	0	0	0,7	0,60	Liten skada
3-1	0	3	0	0	0	0,7	0,008	
3-2	1	3	1	1	1	3,0	1,90	
3-3	0	1	0	0	0	0,7	0,04	
4-1	1	1	1	1	0	1,3	1,1	Når ej kanten
4-2	0	2	0	0	0	0,5	0,007	
4-3	0	0	0	0	0	0,2	0,10	
5-1	1	3	1	1	1	2,8	2,40	
5-2	1	1	1	1	1	7,3	7,00	
6-1	0	1	0	1	0	1,5	0,20	
6-2	2	1	1	1	1	8,6	8,50	Sammanhäng
6-3	1	1	1	0	0	0,6	0,50	liten skada
7-1	1	1	1	1	1	3,3	2,90	
7-2	0	5	1	0	0	0,9	0,40	STOR kvist
7-3	1	2	1	1	1	4,3	3,90	
7-4	0	7	0	1	0	1,2	0,08	
8-1	0	1	0	1	0	2,4	0,01	
8-2	0	0	0	0	0	0,2	0,007	
8-3	1	3	0	0	0	0,5	0,008	Liten skada
9-1	1	2	1	1	1	4,7	3,40	Problematis
9-2	2	1	1	1	1	30,0	29,5	
10-1	1	1	0	1	0	2,9	0,003	Liten skada
10-2	1	1	1	1	1	20,8	19,6	
10-3	1	2	0	1	0	3,3	0,10	Förra stocken
10-4	1	1	0	0	0	0,2	0,03	Liten skada
R3-7-1	0	1	0	0	0	0,5	0,09	
R3-8-2	0	0	0	0	0	0,2	0,04	
R3-9-3	0	1	0	0	0	0,8	0,04	
R4-10-3	0	4	1	0	0	0,7	0,60	Felklassad bark
R4-11-2	0	1	0	0	0	0,2	0,02	
R4-12-1	0	1	0	1	0	4,5	0,1	

Tabell A2. Jämförelse mellan visuellt bedömda mått hos stockar med fetved och motsvarande för algoritmens resultat efter efterbearbetning. I första hand undersöktes komponenter som klarade komponentvillkoret (volym $\geq 0,1$ %) valdes bäst den spatialt bäst matchande komponent manuellt istället. $Z_{CEN,VIS}$ = visuellt bedömd ingångshöjd. $Z_{CEN,ALG}$ = algoritmens masscentrumshöjd. $Z_{LEN,VIS}$ = visuellt bedömd komponentlängd. $Z_{LEN,ALG}$ = algoritmens komponentlängd. Conn betyder att algoritmen tolkade två skador som en, vilket betyder att det inte fanns mer än en komponent att jämföra med.

Stam-stock_sår	Komponent-volym (%)	$Z_{CEN, VIS}$	$Z_{CEN, ALG}$	$Z_{LEN, VIS}$	$Z_{LEN, ALG}$
1-1	3,9	1436	2131	2752	5867
1-2_1	7,6	4890	4935	5905	6914
1-2_2	Conn	7066	Conn	673	Conn
1-2_3	0,1	4707	4723	1577	1232
1-3_1	1,6	6986	6878	6656	2150
1-3_2	0,1	4684	4683	1117	300
2-1_1	15,5	6971	5093	7471	7471
2-1_2	Conn	577	Conn	7471	Conn
2-2	8,4	3027	4726	5032	5022
2-3	0,04	3663	3627	238	81
3-2	1,9	4576	4318	5230	4822
4-1	1,0	8563	6927	7027	5787
5-1	2,3	3968	3762	4988	4063
5-2	6,9	4183	4030	5612	5180
6-2_1	8,5	4130	4128	5634	8012
6-2_2	Conn	2077	Conn	2648	Conn
6-3	0,5	5255	4887	6208	2732
7-1	0,0007	7411	7459	7481	65
7-3	3,9	3455	3247	3734	4200
8-3	0,0004	5967	5965	909	22
9-1	3,4	835	1120	1468	3605
9-2_1	29,5	6072	4958	9350	9350
9-2_2	0,0005	1806	1789	9350	226
10-1	0,0004	3222	3042	665	197
10-2	19,5	4509	8604	8528	8528
10-3	0,03	4579	4435	4579	359
10-4	0,0001	1591	1558	744	56