



Norges miljø- og
biovitenskapelige
universitet

Masteroppgave 2023 30 stp

Fakultet for miljøvitenskap og naturforvaltning

Prediksjon av bonitet i ungskog ved hjelp av laserdata

Site index prediction in young forest using laserdata

Lars Wallerud

Skogfag

Forord

Denne oppgaven markerer slutten for min toårige master i Skogfag ved Fakultet for miljøvitenskap og naturforvaltning (MINA) på Norges miljø- og biovitenskapelige universitet (NMBU) på Ås. Valget av tema falt på bonitetspredikering med bruk av laserdata, da det virket interessant og fremtidsrettet for kartlegging av skogressursene våre. Oppgaven har gitt meg nyttig kunnskap som vil være fordelaktig i yrkeslivet.

Jeg ønsker å takke hovedveilederen min Dr. Ole Martin Bollandsås for hjelp med valg av tema for oppgaven, og god hjelp med bearbeiding av data og gjennomlesinger. En spesiell takk rettes også til min tilleggsveileder, Maria Åsnes Moan, for verdifulle bidrag i forbindelse med databehandlingen og for konstruktive innspill. Bidragene deres har vært avgjørende for den faglige kvaliteten og utførelsen av oppgaven.

Jeg vil også takke mine medstudenter som gjorde studietiden på Ås spennende og interessant. Til slutt vil jeg takke min kjæreste for motivasjon og god hjelp til rettskriving av denne oppgaven.

Norges miljø- og biovitenskapelige universitet

Ås, 13. desember 2023

Lars Wallerud

Sammendrag

I skogforvaltningen er presis bonitetsinformasjon viktig for å ta riktige beslutninger, både med hensyn til valg av tiltak og optimalt tidspunkt for gjennomføring av tiltakene. I de senere årene har flybåren laserskanning (FLS) gjort seg mer bemerket som datainnsamling i skogtaksering. Hovedmålet med denne oppgaven var å utvikle modeller for bonitetspredikering i ungskog med bruk av terrengvariabler som hjelpemidler. I dette studiet er det sett på hvordan terrengvariabler predikerer bonitet ved å sammenlikne bonitet målt i felt, og differansen mellom bonitetsinformasjon fra felt og skogbruksplanen.

I dag finnes det metoder for estimering av bonitet i eldre skog (h.kl III-V) basert på overhøydeendringer predikert med modeller som er avhengig av informasjon fra flybåren laserdata. Derimot er disse metodene mindre egnet for h.kl I-II da det er større sannsynlighet for forstyrrelser i overhøydeutviklingen som følge av inngrep mellom laserdataopptak. Videre er heller ikke bonitetskurvene heller ikke kalibrert på data for yngre skog.

Det er i midlertidig en sammenheng mellom terrengets egenskaper og skogens produktivitet. For eksempel er det som regel høyere produktivitet i hellende terreng sammenliknet med flatt terreng, på grunn av økende næringstransport. Med denne kunnskapen som bakgrunn ønsket jeg i dette å undersøke hvordan terrengvariabler kan brukes som hjelpemidler for å predikere bonitet.

I 2022 ble det gjennomført feltarbeid på studieområdet, hvor 178 prøveflater ble bonitert. Disse flatene er også grunnlaget for referansedataene som ble anvendt for modellene i dette studiet. For å representere terrenget, har terrengvariabler blitt generert fra digitale terrengmodeller. Bonitetsinformasjon fra skogbruksplanen er også hentet inn for ytterligere informasjon. Deretter ble to sett med prediksjonsmodeller utviklet: ett sett som utelukkende er avhengig av terrenginformasjon, og et annet sett som også inkluderer bonitet fra skogbruksplanen.

Resultatene viste at modeller som kun er avhengig av terrenginformasjon for gran har RMSE mellom 3,25 m og 4,14 m. Og for furu har RMSE mellom 2,71 m og 3,91 m. Modeller hvor også informasjon fra skogbruksplan ble inkludert for gran har RMSE mellom 2,78 m og 3,38 m. Og modeller med informasjon også fra skogbruksplan inkludert for furu har RMSE mellom 2,12 m og 3,04 m. Modellene i dette studie predikerer altså bedre med informasjon fra skogbruksplanen.

Abstract

In forest management, accurate site index information is crucial for making informed decisions regarding interventions and determining the optimal timing for these actions. In recent years, airborne laser scanning (ALS) has gained prominence as a data collection method in forest inventory. The primary objective of this study was to develop models for site index prediction in young forests using terrain variables as aids. The study explored how terrain variables predict site index by comparing field-measured site quality, and with the differences between field-measured site index and forestry management inventory.

Existing methods for estimating site index in older forests (development classes III-V) rely on height changes predicted by models dependent on information from airborne laser data. However, these methods are less suitable for development classes I-II due to a higher likelihood of disturbances in height development caused by interventions between laser data captures. Furthermore, the site index curves are not calibrated for younger forests. Nonetheless, there is a connection between terrain characteristics and forest productivity. For instance, sloping terrain generally exhibits higher productivity compared to flat terrain due to increased nutrient transport. With this knowledge as a foundation, the aim was to investigate how terrain variables could be utilized to predict site quality.

Fieldwork was conducted in the study area in 2022, with 178 sample plots being assessed for site index. These plots formed the basis for the reference data used in the models. Terrain variables were generated from digital terrain models to represent the terrain. Site quality information from the forestry management plan was also incorporated for additional context. Two sets of prediction models were then developed: one relying solely on terrain information and another incorporating site index information from the forestry management inventory.

The results indicated that models relying solely on terrain information for spruce had root mean square error (RMSE) between 3.25 m and 4.14 m, while for pine, the RMSE ranged from 2.71 m to 3.91 m. Models that also included information from the forestry management plan for spruce had RMSE between 2.78 m and 3.38 m, and for pine, the RMSE ranged from 2.12 m to 3.04 m. Thus, the models in this study performed better when information from the forestry management inventory plan included.

Innhold

Forord	I
Sammendrag	II
Abstract	III
1. Innledning	1
1.1 Bakgrunn	1
1.2 Bonitering	1
1.3 Flybåren laserskanning og LiDAR-data	2
1.4 Bonitetspredikering i ungskog	4
1.5 Problemstilling	5
2. Materiale og metode	6
2.1 Studieområde	6
2.2 Datainnsamling	7
2.3 Terrengvariabler	8
2.4 Modeller	10
3. Resultater	12
3.1 Modeller	16
3.2 Variabler	21
3.3 DTM-oppløsninger	27
3.4 Areal	30
4. Diskusjon	33
4.1 Prediksjonsmodeller	33
4.2 Bonitetsfordeling	35
4.3 Variabler	35
4.4 DTM-oppløsninger	35
4.5 Areal	36
4.6 Feilkilder	36
4.7 Anvendelighet av metoden	36
5. Konklusjon	37
Referanser	38

1. Innledning

1.1 Bakgrunn

I Norge er 37% av landområdet dekket av skog (Statistisk sentralbyrå, 2023), og skogbruket spiller en betydelig rolle, både økonomisk og spesielt når det gjelder skogens evne til å binde karbon (Pohjola & Valsta, 2007). For å sikre at skogen blir bærekraftig forvaltet til fordel for både skogeiere og klimaet, er bonitet en sentral faktor (Noordermeer et al., 2018). Målet med denne oppgaven er derfor å utvikle modeller for bonitetspredikering av ungskog med bruk av variabler som representerer terregegenskapene.

1.2 Bonitering

Bonitet er en klassifikasjon av skogens evne til å produsere trevirke over tid. I Norge boniterer man vanligvis etter H40-systemet (Tveite, 1977; Tveite & Braastad, 1981). H40-verdien er trehøyden ved en indeksalder på 40 år i brysthøyde, estimert ved bruk av artsspesifikke modeller. Selv om det kan være betydelig variasjon innenfor en bestand i skogen, settes det vanligvis en gjennomsnittlig bonitet i hvert bestand (Bollandsås et al., 2019c).

Tradisjonelt har bonitetsinformasjon blitt innhentet gjennom omfattende feltmålinger, en praksis som både er ressurskrevende og tidkrevende. I de senere årene har imidlertid bruken av fotogrammetri og lasertakst økt, og dette har muliggjort mer effektive og presise estimater for ulike biofysiske egenskaper ved skogen, slik som volum, biomasse, høyde og produktivitet. Muligheten til å innhente mer omfattende data uten behov for omfattende feltarbeid kan forhåpentligvis bidra til å redusere takseringskostnadene hvis resultatene fra lasertakst blir mer presise (Vauhkonen et al., 2014).

Bonitet fra skogbruksplanen kan være upålitelig, og feil i skogbruksplanen kan gi negative økonomiske konsekvenser grunnet feil i tiltakstidspunkt (Noordermeer et al., 2018). Bonitetsinformasjon som hentes fra en skogbruksplan tolkes vanligvis manuelt ut ifra flybilder, og det blir som regel brukt indikasjoner på vekstforholdene basert på observasjoner fra flybildene. I noen tilfeller blir også vurderingene støttet av subjektive feltobservasjoner, prøvemålinger og informasjon fra tidligere registreringer (Noordermeer et al., 2020).

1.3 Flybåren laserskanning og LiDAR-data

En skogeier får den nødvendige informasjonen om skogen sin gjennom en skogbruksplan. I en slik plan finner skogeieren informasjon om hver behandlingsenhet (bestand), slik som treslag, tømmervolum, gjennomsnittlig trehøyde og produktivitet, men også behandlingsforslag for de neste 10-20 årene (Forbund, u.å). Siden tidlig 2000-tallet har datainnsamlingen for utarbeidelse av slike takster blitt gjort gjennom en kombinasjon av flybåren laserskanning (FLS) og feltarbeid (Næsset, 1997a; Næsset, 1997b). FLS er en fjernmålingsteknikk, hvor en aktiv «Light Detection and Ranging» (LiDAR) laserskanner har en aktiv sensor som sender ut laserpulser og registrerer når pulsene reflekteres tilbake fra objekter (Vauhkonen et al., 2014). Man får da dannet en tredimensjonal punktsky som beskriver høyden og tettheten av skogen (Wehr & Lohr, 1999).

LiDAR-systemer montert på fly kan være en kostnadseffektiv måte å skaffe data om skogstruktur for store geografiske områder med høy romlig oppløsning og høy posisjonsnøyaktighet. Begrepet "flybåren laser" brukes ofte for å skille mellom systemer som samler inn LiDAR-data fra fly, og systemer som bruker satellittbårne eller terrestriske plattformer. De fleste kommersielle luftbårne lasere, spesielt de som brukes til operative formål, er utstyrt med en skannerenhet som fordeler det sendte lyset over en bred korridor langs flylinjen. (Vauhkonen et al., 2014).

I det innledende arbeidet til Næsset (1997a, 1997b) ble de første resultatene for potensialet til FLS-data for estimering av gjennomsnittlig trehøyde og bestandsvolum presentert. Senere ble konseptstudier (Næsset 2002a, 2002b) og fullskala demonstrasjoner (Næsset, 2004b) publisert. Til slutt har fullskala bruk i en operativ sammenheng vist at de fleste skogattributter som er relevant for skogskjøtsel kan estimeres med god nøyaktighet (Næsset, 2004a) og til lavere kostnader enn konvensjonelle metoder (Eid et al., 2006).

Siden den første FLS-baserte operasjonelle registreringen ble gjennomført i Nordre Land kommune i 2003 (Næsset, 2004a) har FLS-data blitt en integrert del av den kommersielle skogbrukstaksteringen på alle kontinenter (Maltamo et al., 2014). Lasertakst har blitt brukt siden 2002, og siden den gang har det blitt gjort flere forsøk på å forbedre metoden og redusere kostnader ved å taksere skog. Tidligere har det blant annet blitt sett på om punkttetthet, antall prøveflater (og størrelse) kan påvirke nøyaktigheten til lasertaksering (Næsset & Gobakken, 2008).

En studie gjort av Noordermeer et al. (2018) handler om vekstpotensial med hjelp fra lasertakst. I dette studiet så de på både direkte og indirekte metoder for å bestemme bonitet. De direkte metodene er lignende tradisjonell måte for skoglige variabler ved hjelp av arealbasert lasertakst. For denne metoden trenger man ett sett med parvise observasjoner av feltmålt bonitet og variabler fra bi-temporale laserdata (Noordermeer et al., 2018). Deretter kan statistiske modeller tilpasses og brukes på de egnende beregningscellene (Ole Martin Bollandsås, 2019).

De indirekte metodene innebærer å bruke laserdata til å beregne biomassetthet som igjen skal brukes for å beregne bonitet. Begge disse metodene anvendes på beregningscellenivå. Det som er felles for begge er at overhøydeutviklingen på beregningscellene, hvor boniteten skal bestemmes, må være helt upåvirket mellom tidspunktene de blir målt på. For eksempel hvis det blir hogd i mellomtiden som kan gjøre at overhøyden er lavere enn den ville ha vært uten hogst, vil de beregningscellene det gjelder være uegnet for bonitering ved bruk av laserdata (Bollandsås et al., 2019b). På grunn av at metodene gjelder for skog eldre enn 15 år i brysthøyde, så utgår også beregningsceller i h.kl. II (Bollandsås et al., 2019a).

1.4 Bonitetspredikering i ungskog

Ved dagens skogtakseringer, som er basert på lasermålinger blir ulike ungskogbestander predikert ved hjelp av FLS-data på en måte som er lik metoden for h.kl. III-V. Behovet for ungskogpleie blir da engasjert basert på tetthetsestimater eller ved bruk av en kalibrert tetthetsindeks (Ørka et al., 2015). Metodene som blir brukt gir for øyeblikket ikke tilfredsstillende resultater. Dette er fordi at feilen knyttet til predikert tetthet innen ungskogbestander er for stor ved bruk av kun FLS-data (Næsset & Bjercknes, 2001; Ørka et al., 2016).

Estimater på bestandsnivå er basert på gjennomsnittet av gridceller innenfor et bestand. Disse estimatene gir ikke alltid en nøyaktig indikasjon på behovet for ungskogpleie, som i virkeligheten er den mest relevante informasjonen for fremtidig bestandsforvaltning. Fra dette perspektivet vil det være fornuftig å vurdere en tilnærming der behovet for ungskogpleie forutsies direkte ved hjelp av laserdata. Dette har allerede vist seg å gi lovende resultater når det gjelder tynning av eldre skog (Pippuri et al., 2012; Vastaranta et al., 2011; Watt et al., 2013). På den andre siden konkluderte Korhonen et al. (2013) i sin forskning med at klassifisering av ungskogpleiebehov direkte basert på laserdata, enten ved bruk av logistisk regresjon eller en «support vector machine» (SVM), ikke kan erstatte feltbefaringer fullstendig.

For å oppnå pålitelige data om tetthet og nødvendige tiltak, er det fremdeles nødvendig med feltbefaringer av ungskogbestanden, som dessverre medfører økte takseringskostnader. Hvis man kan forbedre nøyaktigheten av prediksjoner av egenskaper til ungskog, kan dette muligens resultere i betydelige reduksjoner i befaringskostnadene.

1.5 Problemstilling

Dagens metoder for taksering av skog involverer en kombinasjon av felttaksering og FLS. Dette er boniteringsmetoder som er egnet til h.kl. III-V, men som fungerer dårligere på h.kl. I-II. I denne studien ønsket jeg derfor å undersøke om det var mulig å utvikle ulike prediksjonsmodeller ved hjelp av terrengvariabler som blir hentet ut fra en digital terrengmodell (DTM), som videre er generert ut fra FLS.

Årsaken til at det undersøkes om terrengvariabler kan benyttes, er fordi laserskanning vanligvis krever at man registrerer høydeutvikling. Dette betyr at skogen som skal takseres må ha stått urørt. Dermed er terrengvariabler interessante som prediktorer, fordi da blir man ikke avhengig av å skanne trær, men heller av å lage en DTM.

Hovedmålet med denne masteroppgaven var å utvikle prediksjonsmodeller for bonitet med bruk av terrengvariabler, som potensielt kan anvendes i yngre hogstklasser.

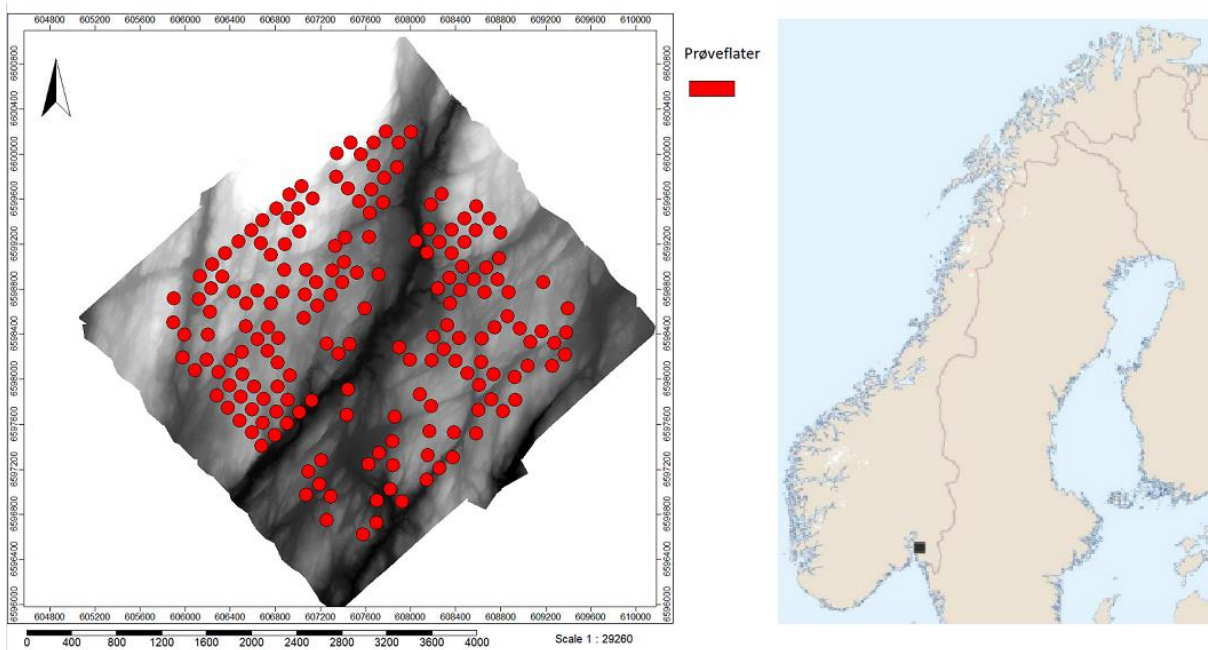
Delproblemstillinger:

- 1) Utvikle modeller som predikerer bonitet med bruk av terrengvariabler.
- 2) Siden det er bonitetsinformasjon fra felt og fra skogbruksplanen vil jeg undersøke om det å inkludere informasjon om bonitet fra skogbruksplanen forbedrer prediksjonen av bonitet med terrengvariabler.
- 3) Identifisere hvilken type terrenginformasjon som er viktigst med tanke på prediksjon av bonitet.

2. Materiale og metode

2.1 Studieområde

Rådata som er brukt i denne oppgaven er hentet fra et forsøksområde i Våler kommune i Viken fylke (Figur 1) sør for Oslo (59°51' N, 10°90' Ø, 70 – 120 moh.). Området omfatter omtrent 850 hektar og skogen er forvaltet med tanke på tømmerproduksjon. Området domineres av gran (*Picea abies*) og furu (*Pinus sylvestris*), men lauvtrær forekommer også, og da i hovedsak bjørk (*Betula ssp.*). Granbestandene i studieområdet ligger for det meste i høyproduktive og fuktige områder lavt i terrenget, hvor avvirkningsmetoden for det meste har vært flatehogst. Furubestandene ligger derimot i høyere og tørrere områder, som er mindre produktive enn områdene med granbestander.



Figur 1. Til venstre: Oversikt over studieområdet og de 178 prøveflatene i et systematisk grid (røde sirkler) Til høyre: Svart kvadrat viser studieområdets lokalisering.

2.2 Datainnsamling

Det aktuelle studieområdet har vært brukt i forbindelse med forskningsaktivitet i mer enn 20 år. Det ble etablert to typer prøveflater der i 1998 (Næsset, 2002a; Næsset, 2002b), hvorav det ene var bestandsflater og det andre var prøveflater. I denne oppgaven er det prøveflatene som ligger til grunnlag. Prøveflatene ble bonitert i 2013, hvor de 4 største trærne av det dominerende treslaget i hver prøveflate ble valgt som boniteringstrær. Trærne som ble valgt ut som boniteringstrær ble høydemålt (fire stk. per flate) og det ble tatt borprøver av trærne (to stk. per flate) for å aldersbestemmelse (Bollandsås et al., 2019c).

Feltarbeidet, hvor deler av dataene for denne studien ble samlet inn, ble utført sommeren og høsten 2022. Det er totalt 178 prøveflater med en størrelse på 400 m². Under feltarbeidet ble hogstklasse for hver flate bestemt, og vurdert til produksjonsskog når middelhøyden i skogen var over 8 meter. Ute i felt ble det først målt grunnflate med relaskop, før det ble utført totalklaving hvor alle trær med en diameter i brysthøyde (dbh) ≥ 4 cm ble registrert. I hver flate ble det valgt ut fire boniteringstrær, og boniteringsarbeidet fra 2013 dannet grunnlaget for boniteringsarbeidet i 2022. Boniteringstrærne fra 2013 ble identifisert ved å bruke avstand og retning fra sentrum av flaten målt i 2013. Siden alder ble bestemt i 2013, kunne man lett finne ny alder ved å addere 9 år. Hvis ikke bonitetstrærne fra 2013 ble gjenfunnet, ble de største trærne av det dominerende treslaget valgt ut slik at det totalt ble fire boniteringstrær. I 2013 ble ikke flater som lå i h.kl. I-II bonitert, dermed ble de fire største trærne av det dominerende treslaget valgt ut som boniteringstrær. Bonitetstrærne som ble valgt for første gang i 2022 ble høydemålt, og det ble også tatt borprøver for aldersbestemmelse for to av trærne.

Bonitet fra skogbruksplanen er hentet inn som bonitetsinformasjon. Bonitetsinformasjonen fra skogbruksplanen er på bestandsnivå.

Heldekkende laserskanning har blitt utført ved studieområdet i Våler i flere omganger, men i denne oppgaven er det kun brukt laserdata fra 2022. Laserskanningen ble utført av Terratec AS. Under skanningen ble en Riegl VQ1560II-S flybåren laserskanner og et Ixm-150RFS kamera brukt. Laser pulsrate var på 2000 khz og flyhøyden var på 940 meter, gjennomsnittlig punktetthet var 33,9 punkter/m².

2.3 Terrengvariabler

Fra laserdataene ble det generert en DTM. For å representere terrengegenskapene til DTM brukte jeg SAGA GIS (Conrad et al., 2015). DTM ble opprettet i ulike oppløsninger (1, 5 og 10 meter) for å inkludere flere oppløsninger i analysene, ettersom ulike oppløsninger har forskjell i detaljer. Hvorav 1 meters oppløsning gir flere detaljer enn for eksempel 10 meters oppløsning (Bratlie, 2015). Hver enkel terrengvariabel ble laget i flere ulike romlige oppløsninger for å kunne ta hensyn til at forskjellige terrengegenskaper har effekt på boniteten på ulik romlig skala, og for å se hvilken romlig skala de har effekt på. De ulike arealene som er prøvd ut er 400 m², 700 m², 1000 m² og 2000 m². Opptelling av antall utvalgte DTM-oppløsninger og antall valgte areal er utført i Excel. Dette er gjort ved å telle antallet av de ulike variablene som er valgt og ført opp i ulike histogram.

I resultatene kan variabler for eksempel stå som «TPI1m_mean_1000», der TPI(1m) indikerer oppløsningen på DTM, «mean» indikerer at det er gjennomsnitt av alle gridcellene i en sirkel, og «1000» indikerer areal (m²) på sirkelen.. Alle variablene som er regnet ut fra alle gridceller inne i en sirkel er gjennomsnittlig verdi «mean», største verdi «max», minste verdi «min» og medianverdi «median».

Variablene som ble benyttet i denne studien var Saga Wetness Index, Slope, Aspect, Terrain Ruggedness Index (TRI), Topographic Position Index (TPI), Direct insolation, Diffuse insolation, ValleyDepth og Depth-to-Water (DTW).

Saga Wetness Index er bortimot lik som Topographic Wetness Index, som kombinerer både Slope og vannstrømninger. Topographic Wetness Index er en kvantitativ indikator som kan vurdere hvor fuktig eller vått det er basert på topografiske egenskaper (Sørensen et al., 2006). Det som skiller Topographic Wetness Index fra Saga Wetness index er at Saga Wetness Index er mer egnet fordi den predikerer celler som ligger i dalbunner bedre ettersom den ikke ser på strømmen som en tynn film (Böhner & Selige, 2006). Slope (helling) og aspect (retning på helling) er valgt som terrengvariabler fordi det ofte er viktige topografiske parametere når man utvikler terrengmodeller (Zhou et al., 2006) og fordi det muligens kan ha en effekt på bonitet ettersom det ofte er våtere i en dalbunn og tørrere på topper.

Direct insolation og diffuse insolation er terrengvariabler man får ut fra SAGA GIS når man henter ut sollysinformasjon fra DTM. Direct insolation er direkte stråling det vil si sollys som treffer direkte uten hindring. Diffuse insolation er sollys som for eksempel er reflektert av vann,

snø, eller av atmosfæren (Sadler, 1975). Disse terrengvariablene ble inkludert, ettersom jeg antar at sollystilgang kan påvirke bonitet.

To andre terrengvariabler som er benyttet er ValleyDepth og Depth-to-water (DTW). Valleydepth beregnes som differansen mellom høyden og en interpolert rygghøyde (Conrad, 2012). DTW refererer til avstanden mellom jordoverflaten og grunnvannet. Disse terrengvariablene er tatt med fordi jeg forutsetter at vanntilgjengelighet også påvirker næringstilgangen (Elgersma, 1998).

2.4 Modeller

Alle analyser ble utført i R (R Core Team, 2022). Først ble det hentet ut terrengvariabler som ble laget i SAGA GIS. Deretter ble gran og furu skilt ut hver for seg i separate datasett for å lage bonitetsmodeller for å finne de forskjellige effektene terrengegenskapene kan ha på de ulike treslagene. Tidyverse er en generell pakke som ble brukt til alt fra datahåndtering til plotting (Wickham et al., 2019).

Bonitetsinformasjon, fra både skogbruksplan og feltregistrert bonitet, er hentet ut slik at jeg kunne lage modeller som kunne forutsi bonitet.

I analysene ble bonitetsdifferansen (Bonitetratio) definert som Feltbonitet (feltregistrert bonitet) dividert på bonitet fra skogbruksplanen (Feltbonitet/bonitet fra skogbruksplanen). Årsaken til at det ble dannet «Bonitetratio» var for å utnytte bonitetsinformasjon som allerede eksisterer på arealet. Modeller som predikerte bonitetratio ble lagd, og så ble bonitet predikert ved å multiplisere bonitet fra skogbruksplanen med predikert bonitetratio.

For å få en bedre forståelse av de identifiserte variablenes sammenheng med bonitet, ble scatterplots laget. Scatterplottene gir en visuell innsikt i hvordan terrengvariablene varierer i forhold til boniteten. For å evaluere modellenes pålitelighet, ble det utført 5-fold-kryssvalidering ved å dele datasettet i fem like store deler med «caret» pakken (Kuhn, 2008). I en 5-fold-kryssvalidering trener man modellen på 4/5 av datamaterialet og tester på resterende 1/5 av datamaterialet. Dette repeteres for alle de 5 oppdelingene av datamaterialet som er brukt, slik at det blir totalt fem iterasjoner. For hver iterasjon ble Root Mean Square Error (RMSE) regnet ut med hjelp av «Metrics» pakken (Hamne & Frasco, 2018), og endelige RMSE var gjennomsnittlig RMSE for alle iterasjoner. RMSE er et mål på gjennomsnittlig avvik mellom predikert verdi og observert verdi (Formel 1).

Formel 1. Formel for RMSE. n er antall prøveflater.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\text{predikert bonitet}_i - \text{observert bonitet}_i)^2}$$

Variabelseleksjon ble utført ved både en manuell og automatisert prosedyre. I den manuelle prosedyren ble det valgt ut ulike sett med variabler basert på eksisterende kunnskap om sammenhengen mellom produksjonsevne og terrengegenskaper og korrelasjoner mellom variablene og bonitet. Hvor gode hver av modellene var ble vurdert ved hjelp av R^2 verdi. I den automatiserte prosedyren ble forklaringsvariablene selektert ved hjelp av «best subset».

Årsaken til at en «best subset» regresjon ble benyttet er fordi denne metoden leter gjennom alle kombinasjoner av variabler, noe som gjør at man kan finne den variabelkombinasjonen som gir best prediksjon (Zhu et al., 2020). Pakken som ble brukt til å lage best subset heter «leaps» (Lumey & Miller, 2020).

Forward-regresjon er en regresjonsanalyse hvor man legger inn variabler en etter en (Hong et al., 2019). Variabelen som ga den beste forbedringen til modellen, var den som ble lagt til. Backward-regresjon er det motsatte av Forward-regresjon. I denne analysen starter prosessen med alle variabler, men fjerner variablene som gjør modellen dårligere.

Ved bruk av Random Forest-regresjon (RF) lages det flere beslutningstrær basert på tilfeldige utvalg av variabler og observasjoner fra data. Hvert beslutningstre kommer fram til en beslutning og så vektet disse beslutningene sammen til én beslutning (Breiman, 2001). RF kan oppdage samspill mellom variabler og vise hvor viktig variabler er (Bjelanovic et al., 2018). Vi brukte pakken «ranger» for å lage RF (Wright & Ziegler, 2017). Jeg regnet også ut Variable Importance in the Projection (VIP), ett mål på hvor viktig variablene er og så lagde jeg en annen RF modell med hundre av de beste variablene som mulige prediksjonsvariabler.

For hver modell ble determinasjonskoeffisienten (R^2) og RMSE beregnet, og i tillegg regnet jeg ut to andre RMSE-verdier (Tabell 1) for kunne ytterligere å undersøke bidraget til terrenginformasjonen med tanke på prediksjon av bonitet. Den første av disse RMSE-verdiene var RMSE hvis man bruker bestandsboniteten fra skogbruksplanen på hver flate (Formel 2). Den andre av disse RMSE-verdiene var RMSE ved å gjette på boniteten. Jeg har her tenkt at man gjetter gjennomsnittsboniteten målt i felt hver gang. Denne RMSE-verdien ble regnet ut ved formel 3. Verdiene står i tabell 1, som «Skogbruksplan» og «gjennomsnitt bonitet».

Formel 2. Fremgangsmåte for å beregne RMSE mellom Feltbonitet og bonitet fra skogbruksplanen.

$$\sqrt{\frac{\sum_{i=1}^n (\text{Feltbonitet}_i - \text{bonitet fra skogbruksplanen}_i)^2}{n}}$$

Formel 3. Fremgangsmåte for å beregne RMSE mellom Feltbonitet og gjennomsnittet fra bonitet fra felt.

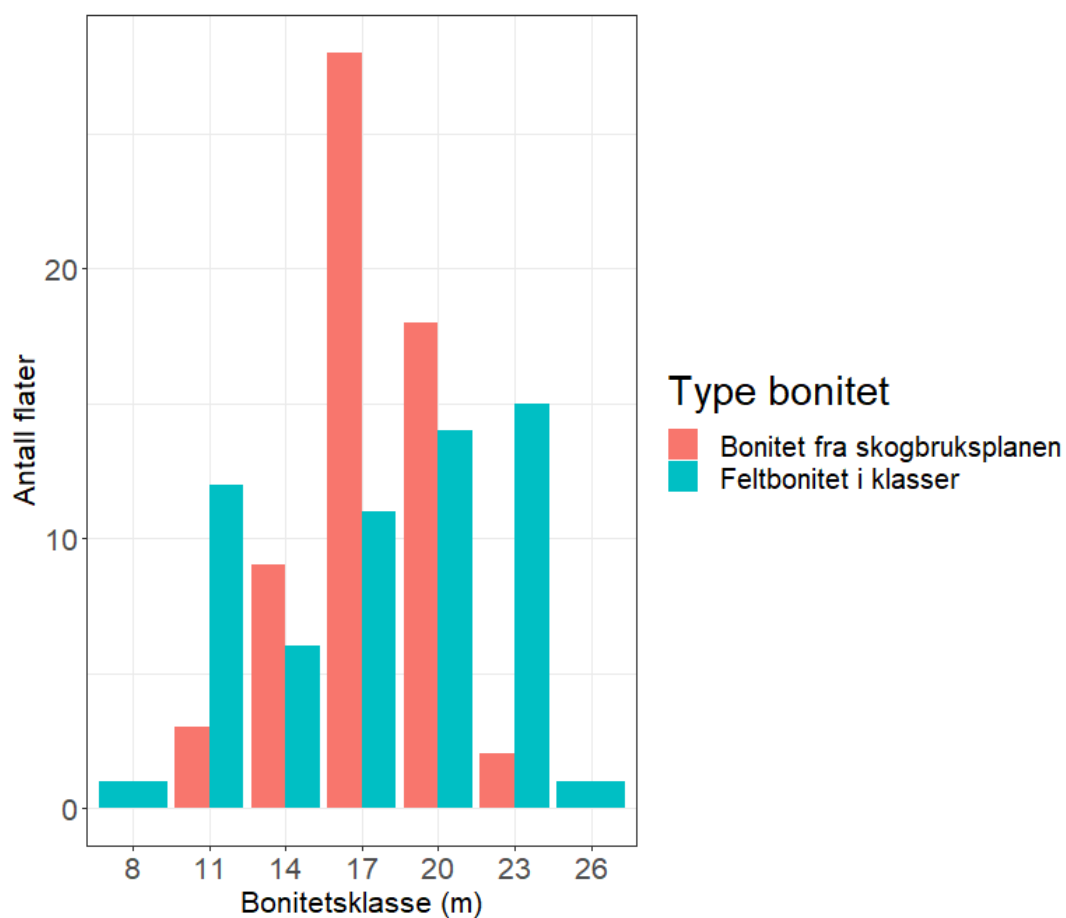
$$\sqrt{\frac{\sum_{i=1}^n (\text{Feltbonitet} - \text{gjennomsnittsbonitet fra Feltbonitet})^2}{n}}$$

3. Resultater


Feltbonitet ble målt som kontinuerlig variabel. Imidlertid ble Feltbonitet regnet om til bonitetsklasser for å muliggjøre en sammenligning av Feltbonitet og bonitet fra skogbruksplanen (Figur 3).

Bonitet 6 og 26 og kun registrert i Feltbonitet og andelen av bonitet 23 er mye høyere enn i bonitet fra skogbruksplanen. Bonitet fra skogbruksplanen har en mye større andel i bonitet 17 enn det er i Feltbonitet (Figur 1).

Bonitetratio ble laget ved å dividere Feltbonitet på bonitet fra skogbruksplan. Hvis verdiene fra Feltbonitet og bonitet fra skogbruksplan hadde vært likt, ville verdien vært 1 (Figur 2). Gjennomsnittlig Bonitetratio var henholdsvis over og under verdien 1 for gran og furu. Det var altså i gjennomsnitt høyere verdier for Feltbonitet sammenlignet med boniteten fra skogbruksplanen for gran, men omvendt for furu.

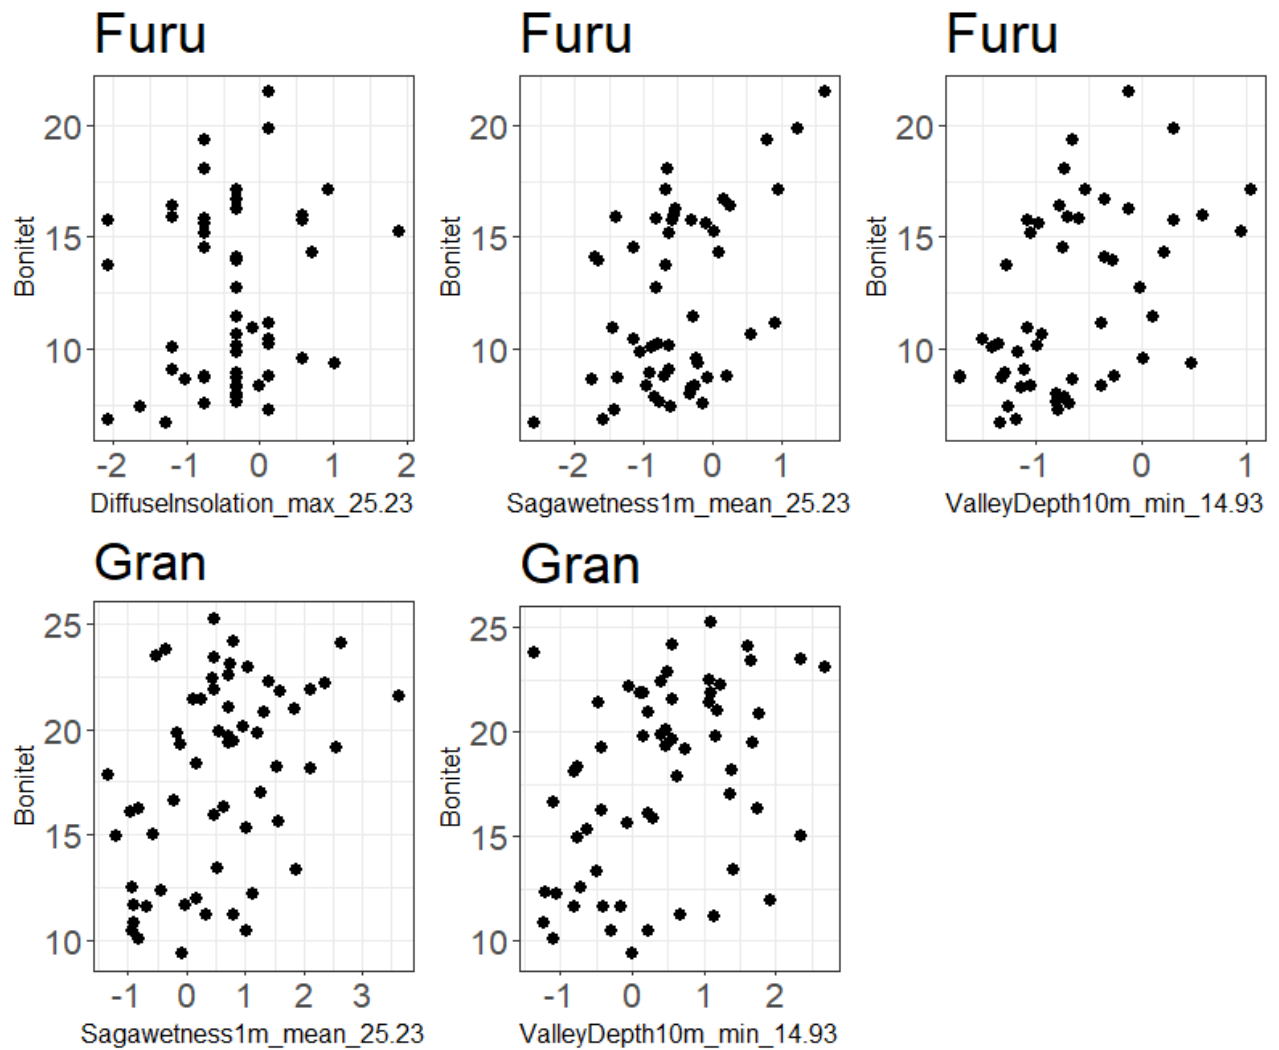


Figur 1. Oversikt over antall flater i de ulike bonitetsklassene fra bonitet fra skogbruksplanen og Feltbonitet i klasser. Feltbonitet er opprinnelig kontinuerlig, men er klassifisert her for å vise antall flater.



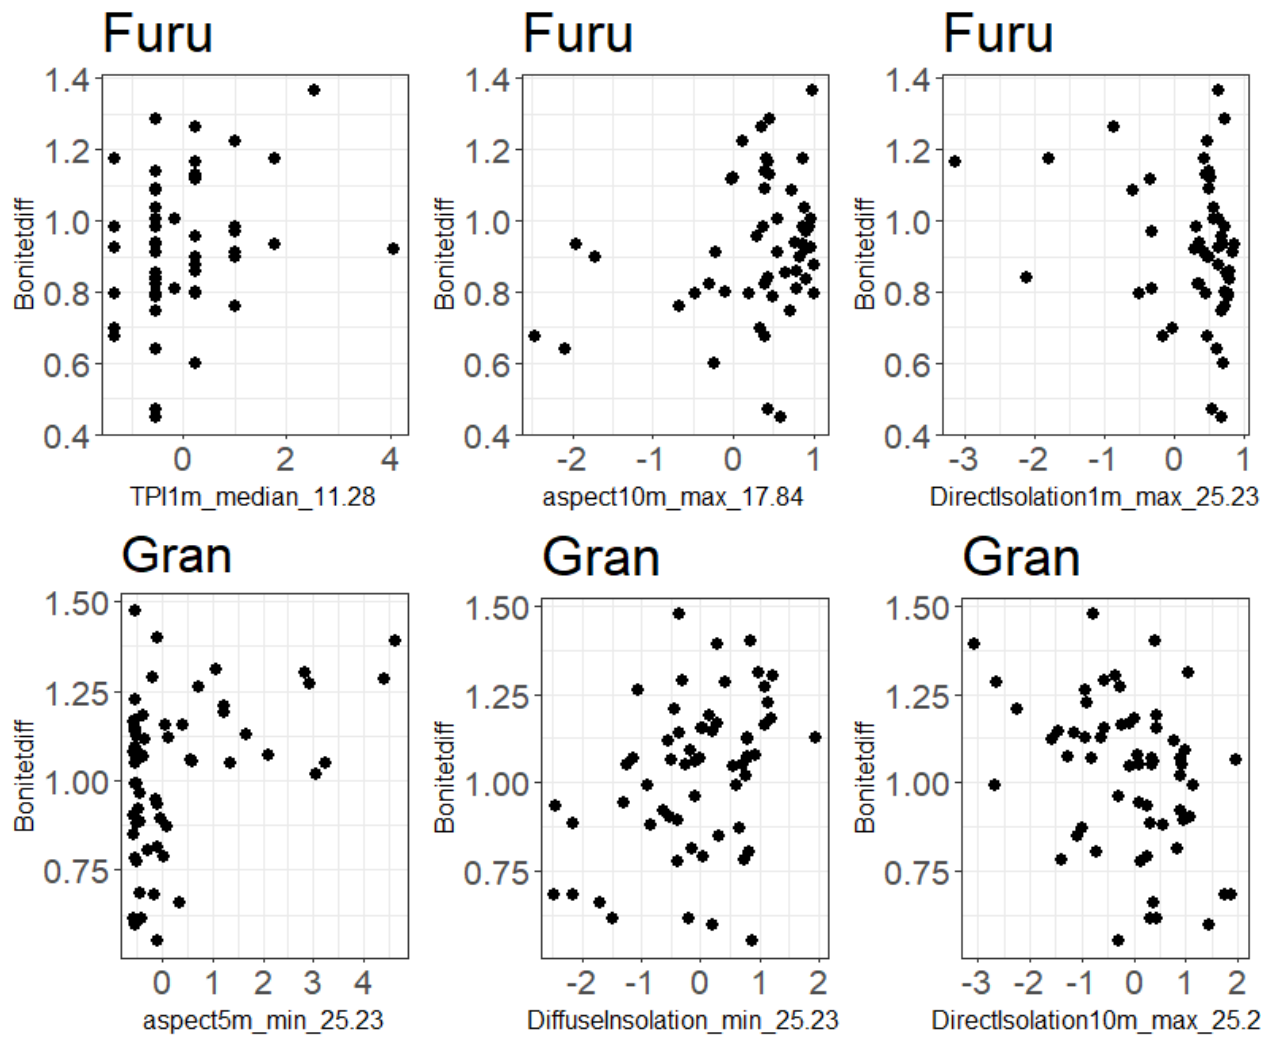
Figur 2. Boksploott for Bonitetratio for gran og furu.

Sagawetness1m_mean25.23(2000m²) viste mer sammenheng enn for eksempel DiffuseInsolation_max_25.23(2000m²) (Figur 3).



Figur 3. Scatterplot av variabler valgt fra manuell metode for prediksjonsmodellen for Feltbonitet.

For Bonitetratio ser man en viss lineær sammenheng, derimot er noen av flatene mer samlet på en side (Figur 4).



Figur 4. Scatterplot av variabler valgt med manuell metode for prediksjonsmodellen for Bonitetratio.

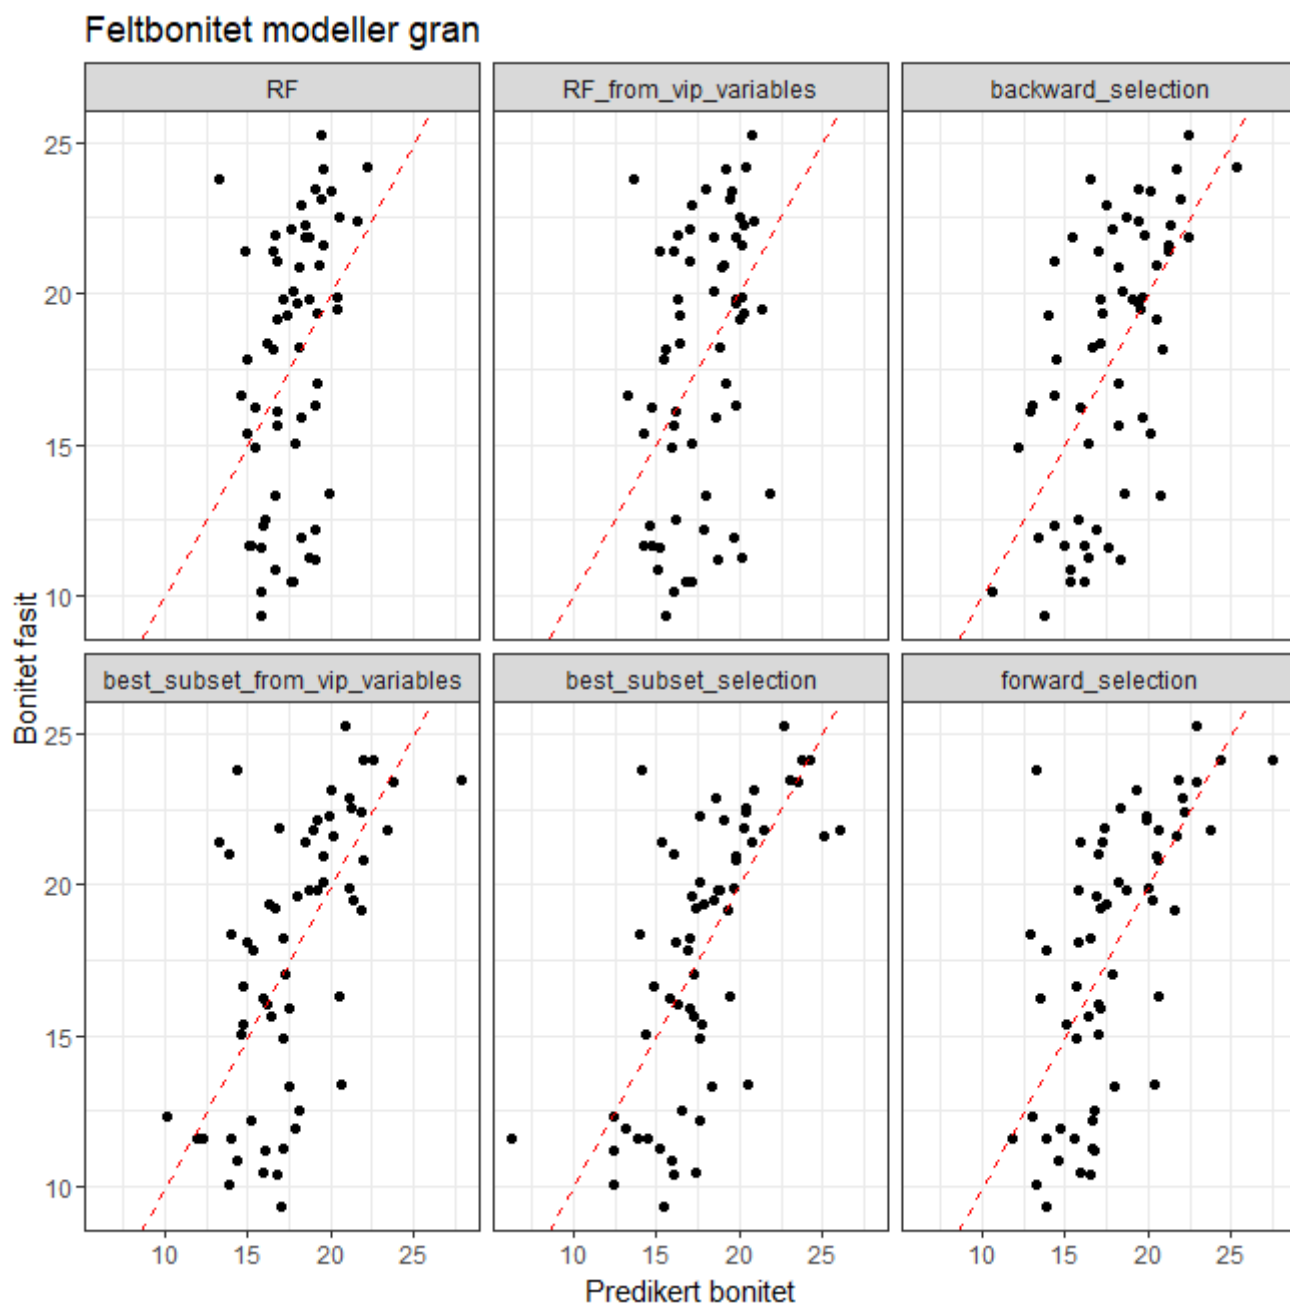
3.1 Modeller

RMSE for Feltbonitet gran er høyere enn Bonitetratio gran, men har lik R^2 -verdi. Den beste modellen er best subset basert på RMSE og R^2 - verdiene. Gran har generelt høyere RMSE verdier for både Feltbonitet og Bonitetratio. Furu har høyest R^2 -verdier for Feltbonitet og gran har generelt høyest R^2 -verdier for Bonitetratio. Best subset for Bonitetratio gran hadde et bedre estimat på 0,81 m eller 4,57% hvis man sammenlikner med kun bruk av bonitet fra skogbruksplanen. Og Best subset for furu hadde et bedre estimat på 0,95 m eller 7,83% (Tabell 1).

Tabell 1. RMSE og R^2 verdier for de ulike analysene for Feltbonitet og Bonitetratio.

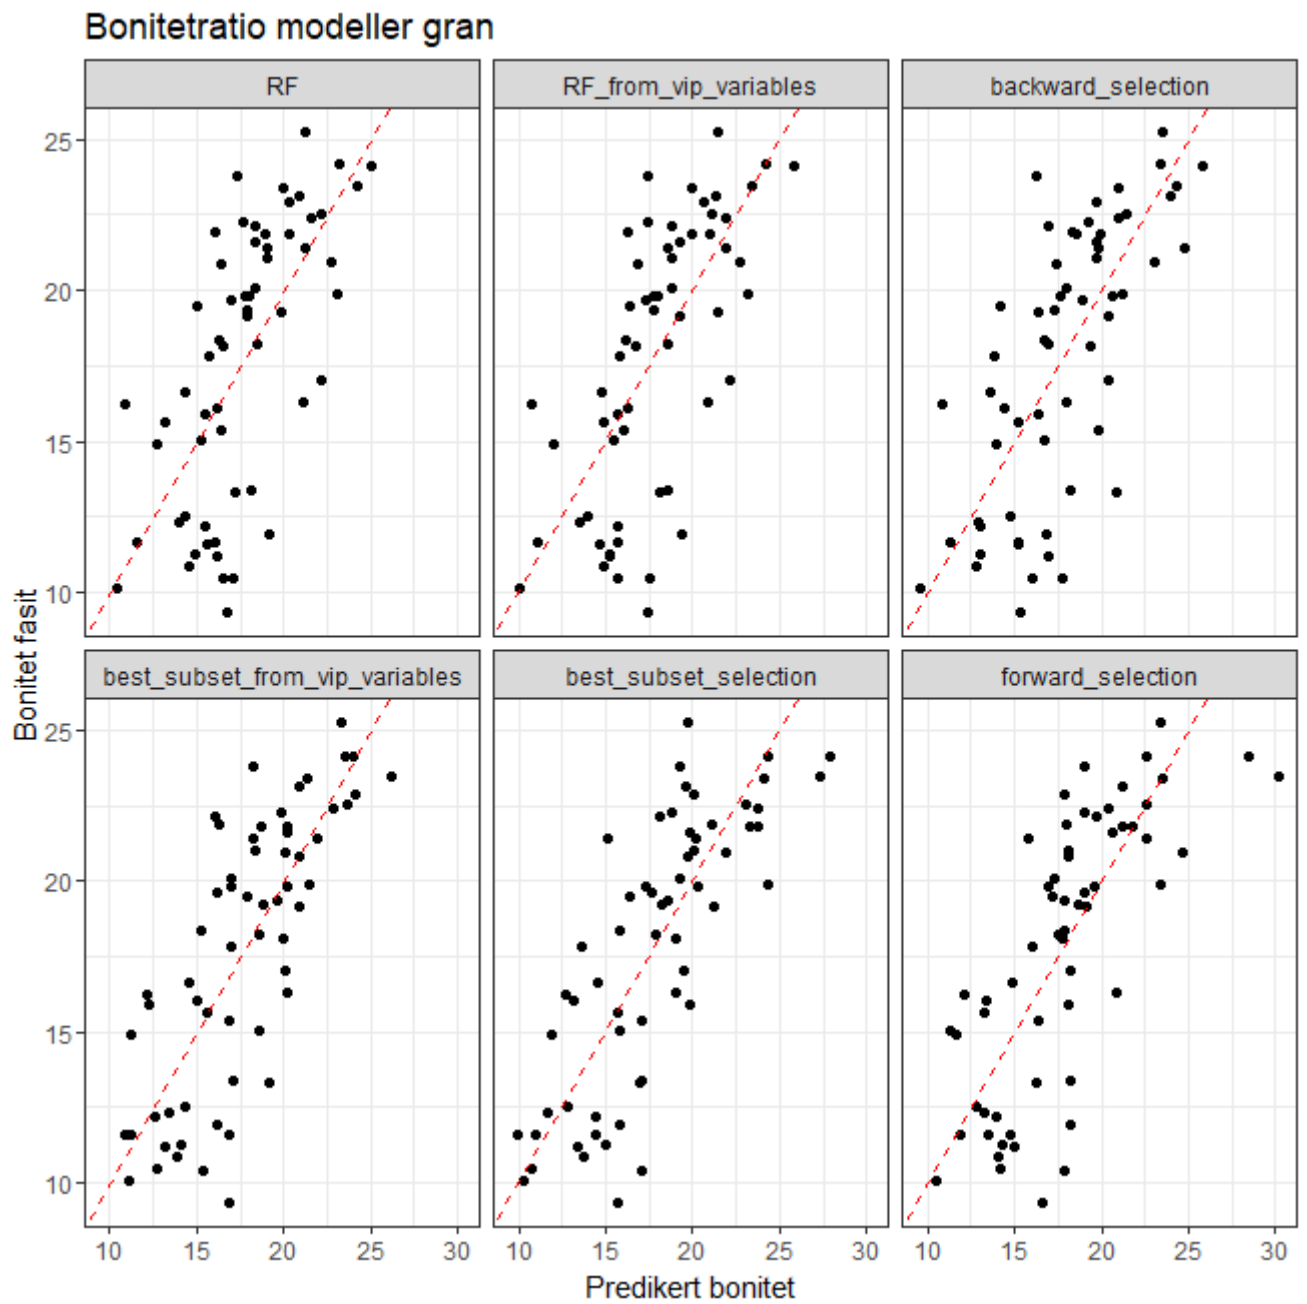
Modell	Feltbonitet				Bonitetratio			
	RMSE		R^2		RMSE		R^2	
	Gran	Furu	Gran	Furu	Gran	Furu	Gran	Furu
Manuell metode	4,00	3,22	0,23	0,35	3,17	2,70	0,23	0,15
Best subset	3,25	2,71	0,49	0,51	2,78	2,12	0,41	0,38
Forward selection	3,35	2,93	0,44	0,47	3,08	2,58	0,31	0,26
Backward selection	3,58	3,57	0,36	0,25	3,21	2,68	0,17	0,06
Best subset from VIP	3,58	2,71	0,43	0,51	2,88	2,21	0,32	0,33
RF	4,10	3,91			3,38	3,04		
RF fra VIP	4,14	3,77			3,31	2,96		
Skogbruksplan	3,59	3,07						
Gjennomsnitt bonitet	4,49	3,92						

RF predikerer dårligst for Feltbonitet gran (Figur 5).



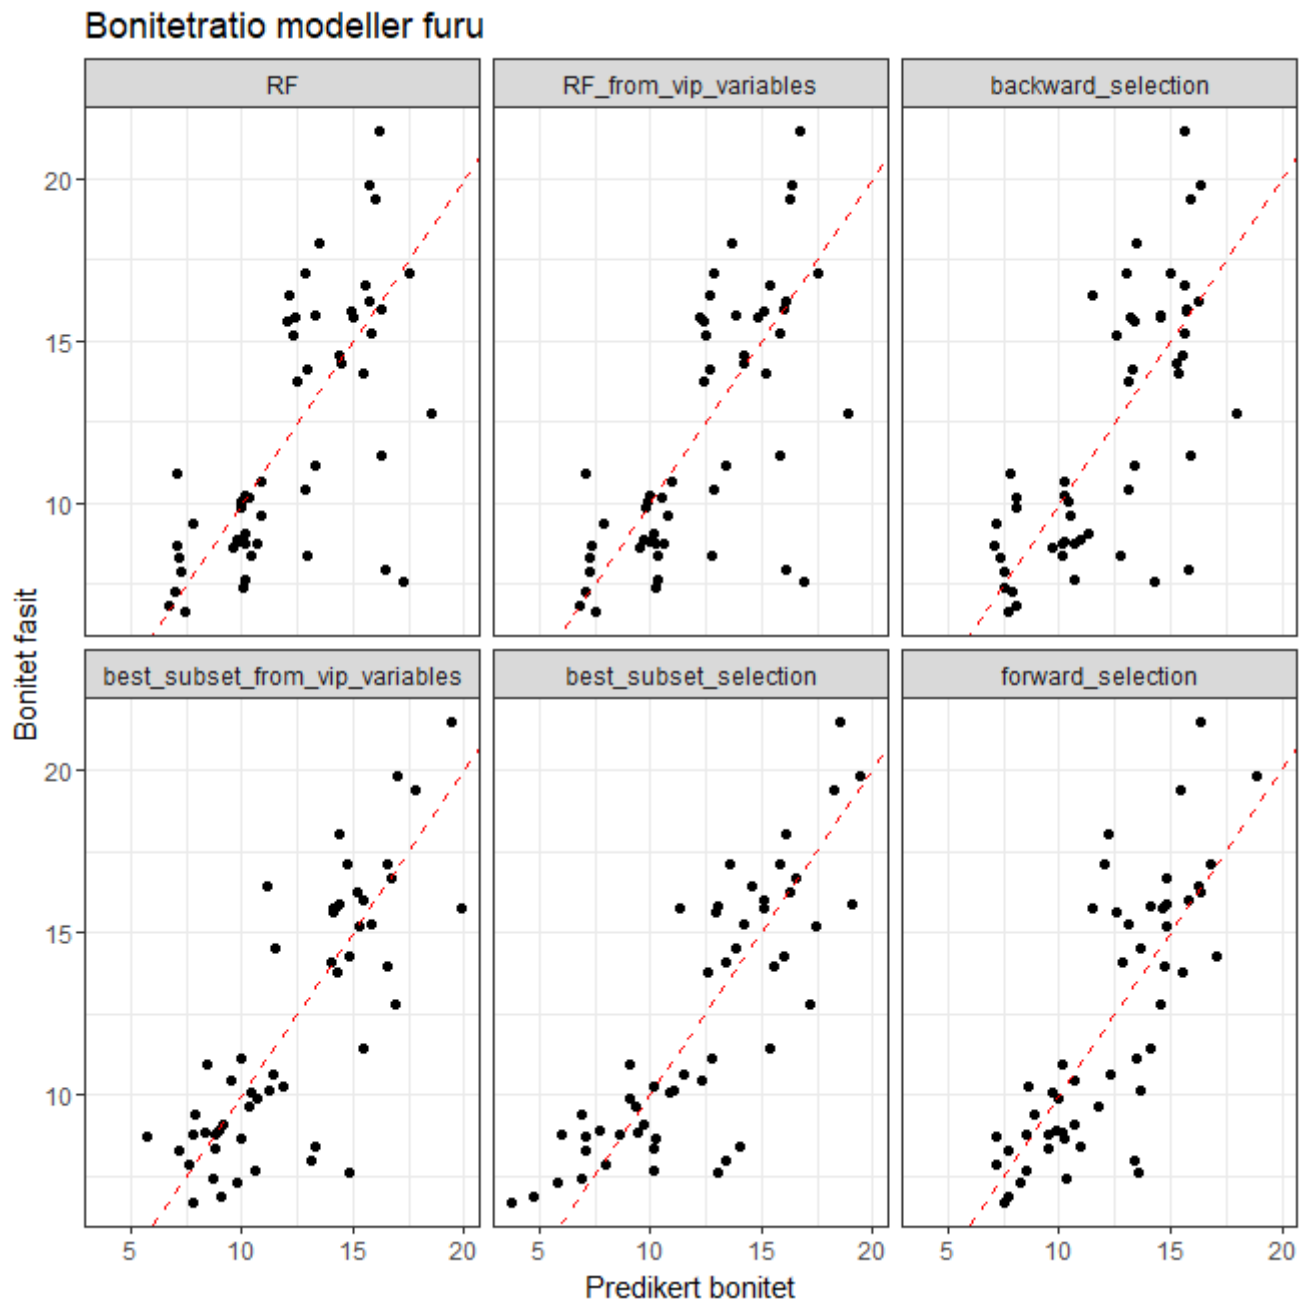
Figur 5. Figuren viser de ulike regresjonsanalysene for Feltbonitet mot predikert bonitet for gran.

RF predikerer bedre for Bonitetratio gran (Figur 6).




Figur 6. Figuren viser de ulike regresjonsanalysene for bonitetratio mot predikert bonitet for gran.

Random Forest viser bedre predikering for Bonitetratio modeller for furu enn det RF gjør for Feltbonitet furu (Figur 7 og 8).



Figur 7. Figuren viser de ulike regresjonsanalysene for Bonitetratio mot predikert bonitet for furu.



Figur 8. Figuren viser de ulike regresjonsanalysene for Feltbonitet mot predikert bonitet for furu.

3.2 Variabler

Tabell 2. Tabellen viser hvilke variabler som ble valgt til hver modell for Feltbonitet gran.

Feltbonitet gran	
Modell	Variabler
Best subset	slope1m_median_1000 Sagawetness1m_mean_1000 ValleyDepth1m_max_2000 DiffuseInsolation5m_mean_400
Forward selection	Sagawetness1m_mean_2000 ValleyDepth1m_min_2000 Ruggedness10m_min_2000 DiffuseInsolation10m_max_2000
Backward selection	slope1m_median_700 TPI1m_median_400 Sagawetness1m_median_700 Sagawetness1m_mean_700
Best subset from VIP	ValleyDepth1m_min_400 DiffuseInsolation_min_2000 ValleyDepth10m_min_400 Ruggedness10m_min_2000

Tabell 3. Tabellen viser hvilke variabler som ble valgt til hver modell for Bonitetratio gran.

Bonitetratio gran	
Modell	Variabler
Best subset	TPI1m_mean_700 DirectInsolation1m_max_400 Ruggedness5m_max_1000 slope10m_max_400
Forward selection	TPI1m_mean_700 Ruggedness1m_max_1000 aspect5m_min_2000 Sagawetness10m_min_400
Backward selection	Sagawetness1m_median_700 Sagawetness1m_mean_700
Best subset from VIP	DirectInsolation5m_max_400 DirectInsolation10m_min_2000 DirectInsolation1m_max_700 Ruggedness5m_max_2000


Tabell 4. Tabellen viser hvilke variabler som ble valgt til hver modell for Feltbonitet furu.

Feltbonitet furu	
Modell	Variabler
Best subset	Ruggedness1m_mean_2000 DiffuseInsolation_mean_2000 ValleyDepth10m_min_400 ValleyDepth10m_min_700
Forward selection	DirectInsolation1m_max_2000 DiffuseInsolation5m_max_700 ValleyDepth10m_min_400 ValleyDepth10m_mean_2000
Backward selection	slope1m_max_1000 TPI1m_min_2000 Sagawetness1m_mean_400
Best subset from VIP	DiffuseInsolation_mean_2000 Ruggedness1m_mean_2000 ValleyDepth10m_min_700 ValleyDepth10m_min_400

Tabell 5. Tabellen viser hvilke variabler som ble valgt til hver modell for Bonitetratio furu.


Bonitetratio furu	
Modell	Variabler
Best subset	TPI1m_mean_1000 Ruggedness1m_mean_2000 Ruggedness5m_median_700 TPI10m_max_400
Forward selection	TPI1m_median_400 DirectIsolation1m_max_2000 aspect10m_min_400 aspect10m_max_1000
Backward selection	aspect1m_median_1000 aspect1m_median_2000
Best subset from VIP	TPI1m_mean_1000 aspect1m_max_400 TPI10m_max_400 TPI5m_min_2000

Valleydepth og Sagawetness er variablene som ble brukt mest, da de er valgt fire ganger hver i modellene for Feltbonitet gran, mens Ruggedness og TPI kun ble brukt en gang (Figur 9).




Figur 9. Stolpediagrammet viser antall ganger variablene er valgt i modeller for Bonitet gran.

Direct Insolation ble valgt fire ganger for Bonitetratio gran, som vil si at det ble brukt flest ganger, i motsetning til slope og aspect som kun ble valgt en gang hver for seg (Figur 10).




Figur 10. Stolpediagrammet viser antall ganger variablene er valgt i modeller for Bonitetratio gran.

Ved Feltbonitet furu er Valleydepth den terrengvariabelen som ble brukt mest, med seks ganger. Videre er DiffuseInsolation valgt halvparten så mye, mens slope, TPI, DirectInsolation og Sagawetness kun ble valgt en gang hver (Figur 11).




Figur 11. Stolpediagrammet viser antall ganger variablene er valgt i modeller for Bonitet furu.

For Bonitetratio furu var det TPI som ble valgt ut mest, med seks ganger (Figur 12).




Figur 12. Stolpediagrammet viser antall ganger variablene er valgt i modeller for Bonitetratio furu.

Sagawetness er den variabelen som ble valgt mest med syv ganger for alle granmodeller (Figur 13).




Figur 13. Stolpediagrammet viser totalt antall valgte variabler for gran.

For alle furumodeller er Ruggedness valgt mest, da totalt åtte ganger. Terrengvariabelen som er valgt minst for furu er Sagawetness som er kun valgt en gang (Figur 14).



Figur 14. Stolpediagrammet viser totalt antall valgte variabler for furu.

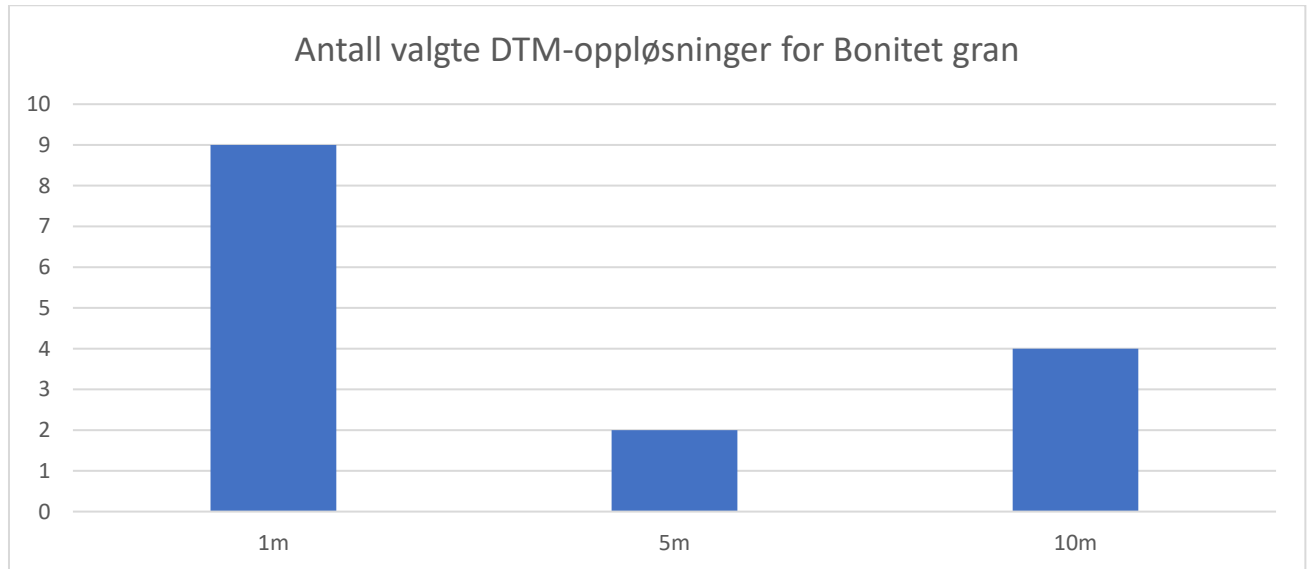
For totalt antall valgte variabler for alle modellene er Valleydepth og TPI valgt desidert mest. Begge variablene er valgt ti ganger (Figur 15).



Figur 15. Stolpediagrammet viser totalt antall valgte variabler alle modellene.

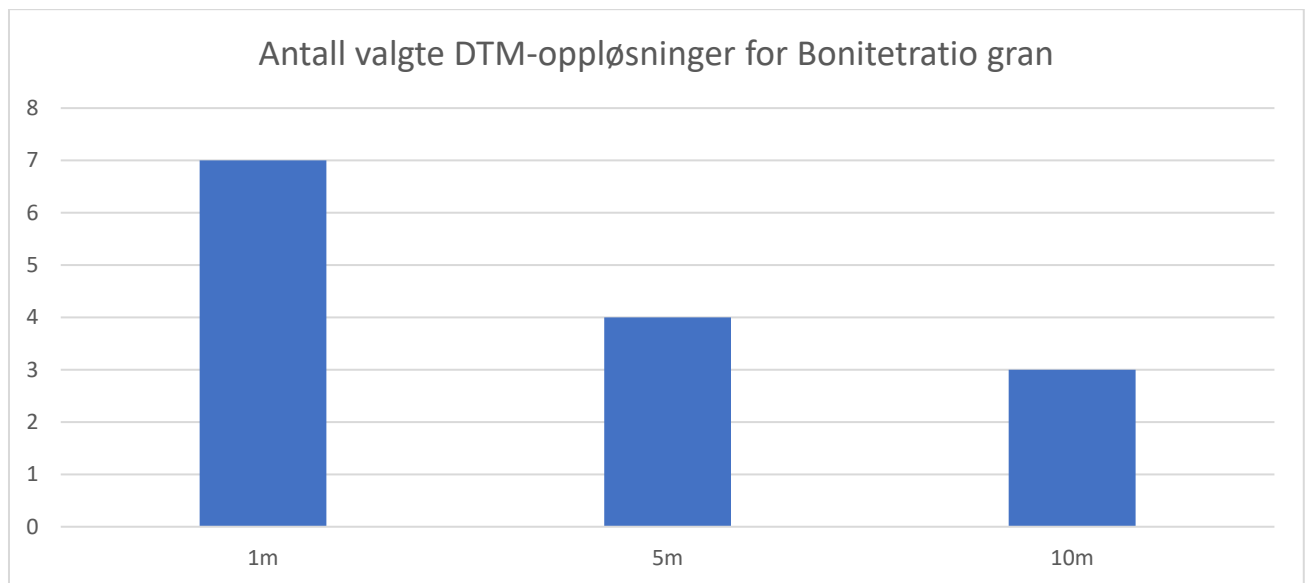
3.3 DTM-oppløsninger

For Feltbonitet gran er 1m DTM-oppløsning valgt mest med ni ganger (Figur 16).




Figur 16. Stolpediagrammet viser utvalgte DTM-oppløsninger for Feltbonitet gran.

For Bonitetratio gran er også 1m DTM-oppløsning valgt mest med syv ganger (Figur 17).




Figur 17. Stolpediagrammet viser utvalgte DTM-oppløsninger for Bonitetratio gran.

For Feltbonitet furu er det 10m DTM-oppløsning som er valgt mest (Figur 18).




Figur 18. Stolpediagrammet viser utvalgte DTM-oppløsninger for Bonitet furu.

For Bonitetratio furu er 1m DTM-oppløsning valgt mest med åtte ganger (Figur 19).




Figur 19. Stolpediagrammet viser utvalgte DTM-oppløsninger for Bonitetratio furu.

For alle granmodeller er 1m DTM-oppløsning valgt mest, 5m og 10m er valgt ut omtrent like mye (Figur 20).




Figur 20. Stolpediagrammet viser totalt utvalgte DTM-oppløsninger for alle modeller for gran.

For alle furumodeller er også 1m DTM-oppløsning valgt mest, 5m er valgt minst (Figur 21).



Figur 21. Stolpediagrammet viser totalt utvalgte DTM-oppløsninger for alle modeller for furu.


Totalt antall valgte DTM-oppløsninger for alle modeller viser at 1m oppløsning er valgt mest (Figur 22).



Figur 22. Stolpediagrammet viser totalt antall utvalgte DTM-oppløsninger for alle modellene.


3.4 Areal

Modellene for Feltbonitet gran valgte variablene med størst areal (2000 m²) med 6 ganger (Figur 23).




Figur 23. Stolpediagrammet viser antall av hvilke areal som ble valgt i modellene for Bonitet gran.

Modellene som for Bonitetratio gran valgte mest terrengvariabler med radius 14.9271 (Figur 24).




Figur 24. Stolpediagrammet viser antall av hvilke areal som ble valgt i modellene for Bonitetratio gran.

Det største arealet (2000 m²) ble valgt mest med syv ganger for Feltbonitet furu, og 1000 m² ble kun valgt en gang (Figur 25).




Figur 25. Stolpediagrammet viser antall av hvilke areal som ble valgt i modellene for Bonitet furu.

Det minste arealet (400 m²) ble valgt mest for Bonitetratio furu (Figur 26).



Figur 26. Stolpediagrammet viser antall av hvilke areal som ble valgt i modellene for Bonitetratio furu.

Totalt sett er det det største arealet (2000 m²) som er valgt mest med tjue ganger for alle modeller. Arealet som ble valgt minst er 1000 m² og det minste arealet (400 m²) er valgt nest mest med sytten ganger (Figur 27).



Figur 27. Stolpediagrammet viser totalt antall valgte areal for alle modellene.

4. Diskusjon

Hovedmålet med denne oppgaven var å finne metoder for predikering av bonitet i ungskog ved bruk av FLS, samt å se om ulike terrengvariabler kunne knyttes til predikering av bonitet. Delmålene med denne oppgaven var videre (1) å utvikle ulike boniteringsmetoder for ungskog med bruk av terrengvariabler og (2) å se hvor presis bonitetspredikeringen er i forhold bonitet fra felt. Bonitetspredikering med bruk av FLS-data er ikke noe nytt, men predikering med terrengvariabler er det gjort mindre forsøk på. Denne oppgaven har derfor fokusert på hvordan terrengvariabler kan predikere bonitet på ungskog hvor laser vanligvis er mindre egnet.

4.1 Prediksjonsmodeller

De lineære modellene viste en viss lineær sammenheng mellom predikert bonitet og bonitet fasit. Bonitet fra skogbruksplanen hadde mindre variasjon av bonitet, som kan være en årsak til at Bonitetratio hadde lavere verdier. I fremtidige forsøk vil det være hensiktsmessig å inkludere bonitet fra skogbruksplanen, selv om den ikke alltid er fullstendig presis. Dersom den tilbyr relevante data om boniteten i bestand, så kan det være brukbar informasjon for modellene.

Ulempen med å bruke informasjon fra skogbruksplan er at den er gitt i en annen skala enn beregningscellene på 400 m², men hvis terrenget reflekterer bestandsvariasjonen så er informasjon uansett til hjelp. Skogbruksplanboniteten vil være mest nyttig for å redusere eventuelle systematiske feil i modellene i dette forsøket. For eksempel hvis to bestand der terrenget ser ganske likt ut (og variablene i forsøket) og det ene bestandet har bonitet 7,5 m og det andre har 21,1 m, mens skogbruksplanen sier 8 m og 20 m. Da er dette informasjon som er veldig nyttig for modellene i dette studie.

Random forest modellen er mest upresis og viser samme tendenser både for Feltbonitet og Bonitetratio. Den viser stor overpredikering av lav bonitet og underpredikerer høy bonitet. En årsak til at denne modellen nødvendigvis ikke er pålitelig, kan være at modellen ikke er like god på å predikere verdier det er lite av (Breiman, 2001).

Gran hadde generelt høyere RMSE og R^2 -verdier enn furu, for manuell metode var RMSE 4,0 m for gran og 3,22 m for furu. RMSE og R^2 -verdiene var generelt lavere for Bonitetratio enn bonitet. Dette medfører at modeller med Bonitetratio kan tilsynelatende virke mindre egnet enn det bonitet fra felt er, men på de grafiske fremstillingene ser modellene for Bonitetratio (Figur 6 og 7) bedre ut til å predikere enn de grafiske fremstillingene for Feltbonitet (Figur 5 og 8).

I en studie gjort av Bjelanovic et al. (2018) i Canada, ble det sett på om depth-to-water (DTW) (markfuktighetskart) hentet fra DTM kunne predikere bonitet for ulike treslag (osp, furu og gran). Resultatene viste at modellen fungerte best på gran som hadde en R^2 verdi på 0,27 (Bjelanovic et al., 2018). Dette er lignende R^2 -verdien fra resultatene i Tabell 1, som viser 0,23 for gran for manuell metode.

Noen av modellene overpredikerer boniteten av lave boniteter og underpredikerer høye boniteter, spesielt modellene for Feltbonitet (Figur 6 og 10). Modellene for bonitetratio ser ut til å treffe bedre på predikering, så det kan hende at bonitet fra skogbruksplanen bidro til bedre resultater for modellene.

I 2006 gjennomførte Böhner og Selige (2006) et forsøk i Tyskland som omhandlet predikering av jordattributter med bruk av terrengvariabler hentet fra DTM. I dette studiet ble konkludert med at bruk av terrengvariabler kan øke presisjonen på estimering av jordattributter (Böhner & Selige, 2006). Likhetene mellom studiet til Böhner og Selige (2006) og dette studiet, er at resultatene antyder en litt forbedret prediksjonsevne ved å inkludere terrengvariabler som er utledet fra DTM. Dette ser man i Tabell 1, som viser hvor mye terrenget har bidratt.

Punktskyen som er brukt i dette studiet er forholdsvis detaljert, og er overskridende det man finner i en vanlig skogbruksplantakst. I fremtidige studier ville det være av interesse å se hvordan resultatene påvirkes ved å bruke en punktsky som har en punkttetthet som er vanlig i en takst. Dersom denne tilnærmingen viser seg effektiv, kan det ha nytte for fremtidige takster, spesielt siden de ikke opererer med den samme punkttettheten som er benyttet i denne studien.

4.2 Bonitetsfordeling

Det var forskjellig spredning av bonitetsklasser i bonitet fra skogbruksplanen og bonitet som var feltregistrert. Bonitet fra skogbruksplanen hadde ikke registrert den laveste og høyeste boniteten (Figur 6 og 26) som ble funnet i feltregistrert bonitet. Årsaken til at bonitet fra skogbruksplanen ikke registrerte disse bonitetene kan være fordi at skogbruksplanen oppgir bonitet på bestandsnivå, og dette informerer ikke om bonitetsforskjeller i bestand. Derimot hadde bonitet fra skogbruksplanen flere observasjoner fra bonitetsklasse 17 (over 25), i motsetning til Feltbonitet som registrerte litt over 10 observasjoner (Figur 1).

4.3 Variabler

For alle modellene er det Valleydepth og TPI som ble valgt mest med ti ganger hver (Figur 16). Saga Wetness og Ruggednes ble valgt åtte ganger hver, som gjør at de to variablene er de nest mest valgte. Disse fire variablene antas å være de viktigste i denne studien, da de trolig kan gi en indikasjon på vanntilgang og jorddybden. Vanntilgang og jorddybde er viktig for vekstpotensial (Dos Reis et al., 2020).

4.4 DTM-oppløsninger

I dette studie ble det brukt flere oppløsninger på DTM for å få en mer detaljert analyse av mindre områder. Bedre oppløsning gir bedre mulighet til å representere terrenget mer presist og tar hensyn til variasjon på fin skala.

1 meters oppløsning på DTM ble valgt mest med tretti ganger for alle modellene (Figur 23). 1 meters oppløsning gir mest detaljer. Oppløsningen på 10 meter gir minst detaljer og er valgt nest mest (Figur 23). En årsak til dette kan være at nede i en dalbunn hvor flaten er liten, så velger den mindre oppløsning, kontra hvis det for eksempel er flatt så blir høyere oppløsning valgt.

4.5 Areal

Det var det største arealet på 2000 m² modellene valget mest totalt (Figur 27). Modellene for Feltbonitet både for gran og furu valgte det største arealet mest (Figur 24 og 26). Derimot valgte Bonitetratio for gran 700 m² mest som er det nest minste arealet (Figur 25). Basert på resultatene i dette studiet kan de se ut som at modellene som ikke har hatt informasjon fra skogbruksplanen, har preferert større areal.

4.6 Feilkilder

Random forest modellen er mest upresis, og den viser samme tendenser både for bonitet og bonitetratio. Den viser stor overpredikering av lav bonitet, og underpredikerer høy bonitet. En årsak til at modellen ikke er pålitelig kan være modellen ikke er like god på å predikere verdier hvis det finnes verdier det er lite av (Breiman, 2001).

4.7 Anvendelighet av metoden

Modellene fra denne oppgaven kan for eksempel brukes på snaumark hvor det til nå har vært vanskelig å utføre bonitering. Dette er med tanke på at det kun blir benyttet info fra terrenget. Selv om metoden ikke nødvendigvis er helt presis, kan den fungere som et verktøy for å gi en generell informasjon om det bestemte området som skal takseres. Siden informasjon om ungskogareal har blitt dårligere på grunn av mindre feltbefaring (Ørka et al., 2015), er spørsmålet om dette kan være ett steg videre for å utvikle bedre prediksjonsmodeller for ungskog.

5. Konklusjon

Resultatene fra studiet gir en indikasjon på at det er mulig å predikere bonitet ved hjelp av terrengvariabler. Og det kan være interessant med videre forskning på dette. Resultatene viser at ved å bruke bonitet fra skogbruksplan øker presisjonen på bonitetspredikeringsmodellene da bonitetsratio modellene hadde lavere RMSE enn Feltbonitet modellene. RMSE ble bare litt forbedret ved å bruke den beste Bonitetratio modellen i forhold til å bare bruke bonitet fra skogbruksplan, noe som tyder på at ekstrainformasjon fra terrenget ikke bidrar mye.

Med tanke på hvor problematisk laserskanning i ungskog kan være, på grunn av forstyrrelser, demonstrerer funnene at terrengvariabler har en viss grad av relevans for å predikere bonitet.

Referanser

- Bjelanovic, I., Comeau, P. & White, B. (2018). High Resolution Site Index Prediction in Boreal Forests Using Topographic and Wet Areas Mapping Attributes. *Forests*, 9 (3). doi: 10.3390/f9030113.
- Bollandsås, O. M., Noordermeer, L., Dypsund, S., Gobakken, T. & Næsset, E. (2019a). Bonitering av skog i andre omdrev av skogbruksplantakster basert på laser eller flybilder.
- Bollandsås, O. M., Noordermeer, L., Dypsund, S., Gobakken, T. & Næsset, E. (2019b). Sluttrapport bonitering med flybåren laser.
- Bollandsås, O. M., Ørka, H. O., Dalponte, M., Gobakken, T. & Næsset, E. (2019c). Modelling site index in forest stands using airborne hyperspectral imagery and bi-temporal laser scanner data. *Remote Sensing*, 11 (9): 1020.
- Bratlie, R. (2015). Beregning av flomveier med eksempler på bruk i kommunal forvaltning. *Kart og Plan*, 75 (1): 24-34.
- Breiman, L. (2001). Random forests. *Machine learning*, 45: 5-32.
- Böhner, J. & Selige, T. (2006). Spatial prediction of soil attributes using terrain analysis and climate regionalisation. I: *SAGA-Analyses and modelling applications*: Goltze.
- Conrad, O. (2012). Module valley depth. *System for Automated Geoscientific Analyses. SAGA*.
- Conrad, O., Bechtel, B., Bock, M., Dietrich, H., Fischer, E., Gerlitz, L., Wehberg, J., Wichmann, V. & Böhner, J. (2015). System for automated geoscientific analyses (SAGA) v. 2.1. 4. *Geoscientific Model Development*, 8 (7): 1991-2007.
- Dos Reis, A. A., Franklin, S. E., Acerbi Júnior, F. W., Ferraz Filho, A. C. & de Mello, J. M. (2020). Classification of Eucalyptus plantation Site Index (SI) and Mean Annual Increment (MAI) prediction using DEM-based geomorphometric and climatic variables in Brazil. *Geocarto International*, 37 (5): 1256-1273. doi: 10.1080/10106049.2020.1778103.
- Eid, T., Gobakken, T. & Næsset, E. (2006). Comparing stand inventories for large areas based on photo-interpretation and laser scanning by means of cost-plus-loss analyses. *Scandinavian Journal of Forest Research*, 19 (6): 512-523. doi: 10.1080/02827580410019463.
- Elgersma, A. M. (1998). Sammenhenger mellom skogtyper, bonitet og jordkjemi i ulike makro klima regioner. *Norsk institutt for jord- og skogkartlegging*.

- Forbund, N. S. (u.å). *Skogbruksplan*. Tilgjengelig fra:
<https://www.skog.no/skogfaglig/skogbruksplan/> (lest 03.12).
- Hamne, B. & Frasco, M. (2018). Evaluation Metrics for Machine Learning.
- Hong, H. G., Zheng, Q. & Li, Y. (2019). Forward regression for Cox models with high-dimensional covariates. *Journal of Multivariate Analysis*, 173: 268-290. doi: 10.1016/j.jmva.2019.02.011.
- Korhonen, L., Pippuri, I., Packalén, P., Heikkinen, V., Maltamo, M. & Heikkilä, J. (2013). Detection of the need for seedling stand tending using high-resolution remote sensing data. *Silva Fennica*, 47 (2).
- Kuhn, M. (2008). Building Predictive Models in R Using the caret Package. *Journal of Statistical Software*: 1-26.
- Lumey, T. & Miller, A. (2020). leaps: Regression Subset Selection.
- Maltamo, M., Næsset, E. & Vauhkonen, J. (2014). Forestry applications of airborne laser scanning. *Concepts and case studies. Manag For Ecosys*, 27: 460.
- Noordermeer, L., Bollandsås, O. M., Gobakken, T. & Næsset, E. (2018). Direct and indirect site index determination for Norway spruce and Scots pine using bitemporal airborne laser scanner data. *Forest Ecology and Management*, 428: 104-114. doi: 10.1016/j.foreco.2018.06.041.
- Noordermeer, L., Gobakken, T., Næsset, E. & Bollandsås, O. M. (2020). Predicting and mapping site index in operational forest inventories using bitemporal airborne laser scanner data. *Forest Ecology and Management*, 457. doi: 10.1016/j.foreco.2019.117768.
- Næsset, E. (1997a). Determination of mean tree height of forest stands using airborne laser scanner data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 52 (2): 49-56. doi: [https://doi.org/10.1016/S0924-2716\(97\)83000-6](https://doi.org/10.1016/S0924-2716(97)83000-6).
- Næsset, E. (1997b). Estimating timber volume of forest stands using airborne laser scanner data. *Remote Sensing of Environment*, 61 (2): 246-253. doi: [https://doi.org/10.1016/S0034-4257\(97\)00041-2](https://doi.org/10.1016/S0034-4257(97)00041-2).
- Næsset, E. & Bjercknes, K.-O. (2001). Estimating tree heights and number of stems in young forest stands using airborne laser scanner data. *Remote Sensing of Environment*, 78 (3): 328-340. doi: [https://doi.org/10.1016/S0034-4257\(01\)00228-0](https://doi.org/10.1016/S0034-4257(01)00228-0).
- Næsset, E. (2002a). Determination of Mean Tree Height of Forest Stands by Digital Photogrammetry. *Scandinavian Journal of Forest Research*, 17 (5): 446-459. doi: 10.1080/028275802320435469.

- Næsset, E. (2002b). Predicting forest stand characteristics with airborne scanning laser.pdf>.
- Næsset, E. (2004a). Accuracy of forest inventory using airborne laser scanning: evaluating the first nordic full-scale operational project. *Scandinavian Journal of Forest Research*, 19 (6): 554-557. doi: 10.1080/02827580410019544.
- Næsset, E. (2004b). Practical large-scale forest stand inventory using a small-footprint airborne scanning laser. *Scandinavian Journal of Forest Research*, 19 (2): 164-179. doi: 10.1080/02827580310019257.
- Næsset, E. & Gobakken, T. (2008). Estimation of above- and below-ground biomass across regions of the boreal forest zone using airborne laser. *Remote Sensing of Environment*, 112 (6): 3079-3090. doi: 10.1016/j.rse.2008.03.004.
- Ole Martin Bollandsås, L. N., Svein Dypsund, Terje Gobakken, Erik Næsset. (2019). Bonitering av skog i andre omdrev av skogbruksplantakster basert på laser eller flybilder.
- Pippuri, I., Kallio, E., Maltamo, M., Peltola, H. & Packalén, P. (2012). Exploring horizontal area-based metrics to discriminate the spatial pattern of trees and need for first thinning using airborne laser scanning. *Forestry*, 85 (2): 305-314.
- Pohjola, J. & Valsta, L. (2007). Carbon credits and management of Scots pine and Norway spruce stands in Finland. *Forest Policy and Economics*, 9 (7): 789-798. doi: 10.1016/j.forpol.2006.03.012.
- R Core Team. (2022). *R: A language and environment for statistical computing*. Vienna, Austria: R Foundation for Statistical Computing. Tilgjengelig fra: <https://www.R-project.org>.
- Sadler, G. (1975). Direct and diffuse insolation using approximation methods applied to horizontal surface insolation. *Solar Energy*, 17 (1): 39-46.
- Statistisk sentralbyrå. (2023). *Skogareal*. SSB. Tilgjengelig fra: <https://www.ssb.no/jord-skog-jakt-og-fiskeri/faktaside/skogbruk> (lest 01.12.2023).
- Sørensen, R., Zinko, U. & Seibert, J. (2006). On the calculation of the topographic wetness index: evaluation of different methods based on field observations. *Hydrol. Earth Syst. Sci.*, 10 (1): 101-112. doi: 10.5194/hess-10-101-2006.
- Vastaranta, M., Holopainen, M., Yu, X., Hyyppä, J., Hyyppä, H. & Viitala, R. (2011). Predicting stand-thinning maturity from airborne laser scanning data. *Scandinavian Journal of Forest Research*, 26 (2): 187-196.

- Vauhkonen, J., Maltamo, M., McRoberts, R. & Næsset, E. (2014). *Introduction to Forestry Applications of Airborne Laser Scanning*, b. 27.
- Watt, M. S., Meredith, A., Watt, P. & Gunn, A. (2013). Use of LiDAR to estimate stand characteristics for thinning operations in young Douglas-fir plantations. *New Zealand Journal of Forestry Science*, 43: 1-10.
- Wehr, A. & Lohr, U. (1999). Airborne laser scanning—an introduction and overview. *ISPRS Journal of photogrammetry and remote sensing*, 54 (2-3): 68-82.
- Wickham, H., Averick, M., Bryan, J., Chang, W., McGowan, L., François, R., Grolemund, G., Hayes, A., Henry, L., Hester, J., et al. (2019). Welcome to the tidyverse. *Journal of Open Source Software*, 4: 1686.
- Wright, M. N. & Ziegler, A. (2017). ranger: A Fast Implementation of Random Forests for High Dimensional Data in C++ and R. *Journal of Statistical Software*, 77 (1): 1-17.
- Zhou, Q., Liu, X. & Sun, Y. (2006). Terrain complexity and uncertainties in grid-based digital terrain analysis. *International Journal of Geographical Information Science*, 20 (10): 1137-1147. doi: 10.1080/13658810600816573.
- Zhu, J., Wen, C., Zhu, J., Zhang, H. & Wang, X. (2020). A polynomial algorithm for best-subset selection problem. *Proc Natl Acad Sci U S A*, 117 (52): 33117-33123. doi: 10.1073/pnas.2014241117.
- Ørka, H. O., Gobakken, T. & Næsset, E. (2015). <Ørka et al. 2015 - Laser2 - Taksering av ungskog med flybåren laserscanning etter arealmetoden.pdf>.
- Ørka, H. O., Gobakken, T. & Næsset, E. (2016). Predicting attributes of regeneration forests using airborne laser scanning. *Canadian Journal of Remote Sensing*, 42 (5): 541-553.



Norges miljø- og biovitenskapelige universitet
Noregs miljø- og biovitenskapelige universitet
Norwegian University of Life Sciences

Postboks 5003
NO-1432 Ås
Norway