



UPPSALA
UNIVERSITET

UPTEC W 25012

Examensarbete 30 hp

Maj 2025

Undersökning av GIS-baserade prediktorer för skattning av markens bärförmåga vid slutavverkning

Ida Johansson



Abstract

Soil compaction and rutting are common problems during forestry operations on weak soils, especially during wet conditions. These impacts can reduce forest growth and long-term soil productivity. GIS-based models estimating soil bearing capacity can guide planning of harvesting and road placement to reduce the risk of such damage. This study aimed to evaluate which geospatial variables best estimate soil strength, expressed as California Bearing Ratio (CBR), and how the generation of Depth-to-Water (DTW) maps influence prediction. Field data from 120 sampling plots across six forest areas around Uppsala were analyzed in relation to GIS variables such as DTW, elevation, slope, forest stand volume, soil depth, and peat layer presence. Both categorized and continuous DTW values were tested, as well as different flow accumulation thresholds (from 0.05 to 10 hectares) used in DTW map creation. Results showed that using a 1-hectare flow accumulation threshold gave the strongest correlation between DTW and CBR ($\rho = 0.37$), suggesting this hydrological scale best reflects soil strength variability. Switching from categorized to continuous DTW values increased the model's R^2 from 0.1 to 0.2, an 87% improvement in explained variance. Adding slope, forest volume, and soil depth increased adjusted R^2 slightly from 0.155 to 0.178. Elevation had a weak correlation with CBR. The best balance between simplicity and predictive performance was achieved with models including DTW, forest volume, and slope (adjusted $R^2 = 0.189$). Field-determined soil type was more reliable than map-based data, and SLU's soil moisture map, which integrating more information than DTW, further improved predictions. However, limitations remain due to sparse sampling, urban forest environments, and the static nature of DTW. In conclusion, DTW-based models, especially when combined with additional variables, show potential for predicting trafficability, though field validation remains important.

Keywords: Soil bearing capacity, California bearing ratio (CBR), GIS, geospatial data, Depth-to-water, regression analysis

Teknisk-naturvetenskapliga fakulteten

Uppsala universitet, Utgivningsort Uppsala

Handledare: Sima Mohtashami Ämnesgranskare: Thomas Grabs

Examinator: Antonio Segalini



Referat

Markpackning och spårbildning är vanliga problem vid skogsavverkning på känsliga marker, särskilt under blöta förhållanden. Dessa problem kan bidra till negativa effekter för skogstillväxt och markens långsiktiga produktionsförmåga. Genom att använda GIS-baserade modeller för att skatta markens bärförmåga kan avverkning och skogsbilvägar planeras så att risken för markskador minimeras. Stödsystem som baseras på geodata kan användas för att vägleda maskinförare till områden med högre bärförmåga. Denna studie syftade till att utvärdera vilka geodata som kan användas för att skatta markstyrka, uttryckt som California Bearing Ratio (CBR), samt hur val vid skapandet av DTW-kartor (Depth-to-Water) påverkar skattningen. Fältdata från 120 provpunkter spridda över sex skogsområden kring Uppsala analyserades i relation till GIS-variabler som DTW markfuktighetskarta, topografi (höjd över havet och lutning), virkesförråd, jorddjup och torvlagrets mäktighet. Både kategoriserade och kontinuerliga DTW-värden testades, liksom olika tröskelvärden för flödesackumulation (från 0.05 till 10 hektar) vid generering av DTW-kartor. Resultaten visade att användning av ett tröskelvärde på 1 hektar gav starkast korrelation mellan DTW och CBR ($\rho = 0.37$), vilket tyder på att detta tröskelvärde bäst speglar variationen i markstyrka. Att gå från kategoriserade till kontinuerliga DTW-värden ökade modellens justerade R^2 från 0.062 till 0.155. Tillägg av lutning, virkesförråd och jorddjup ökade justerat R^2 ytterligare till 0.178. Höjd över havet hade svag korrelation med CBR och inkluderades inte i modellerna. Den bästa balansen mellan enkelhet och prediktiv förmåga uppnåddes med modeller som inkluderade DTW, virkesförråd och lutning (justerat $R^2 = 0.189$). Jordartsinformation från fält var mer tillförlitlig än kartbaserad data, och SLU:s markfuktighetskarta, som integrerar DTW och hydrologisk modellering, förbättrade prediktionen ytterligare. Begränsningar kvarstår dock på grund av gles provtagning, urbana skogsmiljöer och DTW:s statiska karaktär. Sammanfattningsvis visar DTW-baserade modeller, särskilt i kombination med andra variabler, potential för att förutsäga framkomlighet, men fältverifiering är fortsatt viktigt.

Nyckelord: Markens bärförmåga, California bearing ratio (CBR), GIS, geodata, Depth-to-water (DTW), regressionsanalys

Institutionen för geovetenskaper, Luft-, vatten- och landskapslära, Uppsala universitet, Villavägen 16, SE-752 36 Uppsala, Sverige

Teknisk-naturvetenskapliga fakulteten

Uppsala universitet, Utgivningsort Uppsala

Handledare: Sima Mohtashami Ämnesgranskare: Thomas Grabs

Examinator: Antonio Segalini

Förord

Detta examensarbete har genomförts som ett sista moment av mina fem år av studier vid civilingenjörsprogrammet i miljö- och vattenteknik vid Uppsala universitet och Sveriges lantbruksuniversitet. Arbetet har utförts i samarbete med Skogforsk och handledare för arbetet var Sima Mohtashami på Skogforsk. Ämnesgranskare var Thomas Grabs från institutionen för geovetenskaper, luft-, vatten- och landskapslära, hydrologi på Uppsala universitet.

Först och främst vill jag tacka min handledare, Sima Mohtashami för vägledning och insiktsfulla perspektiv genom hela arbetet. All input har varit till stor hjälp för att utveckla och förbättra arbetet. Tack också till min ämnesgranskare Thomas Grabs för konstruktiva kommentarer och värdefull feedback.

Jag vill även rikta ett stort tack till Lars Eliasson och Linnéa Hansson för vägledning och hjälp under arbetets gång. Ett särskilt tack går också till Skogforsk för att jag fått möjlighet att genomföra mitt examensarbete där. Jag har känt mig väldigt välkommen och det har varit lätt att trivas, särskilt tillsammans med kommunikationsgänget där jag haft min plats. Det har varit en lärorik och utvecklande tid och jag uppskattar alla insikter och kunskaper jag fått genom att arbeta med detta område.

This thesis work has been funded by the US department of agriculture, NIFA funded research project “PARTNERSHIP: Sustainable Forest Management through Enhanced Harvest Planning and Modeling to Minimize Impacts on Forest Soils and Tree Growth” (Award no: 20246701942511).

Populärvetenskaplig sammanfattning

Skogen är en viktig resurs i Sverige, både ekonomiskt, ekologiskt och socialt. Men när skogen brukas, särskilt vid avverkning, kan problem uppstå. En av de största utmaningarna är att undvika skador på marken när tunga maskiner, som skotare och skördare, körs i terrängen. I fuktiga eller mjuka områden kan maskinernas vikt göra att det bildas djupa spår eller att marken packas ihop vilket exempelvis kan leda till att vatten får det svårare att tränga ner. Sådana skador kan försämra trädens tillväxt och påverka markens hälsa under lång tid. För att undvika detta är det därför viktigt att veta var marken är svag och känslig och var man inte bör köra. Traditionellt bedöms det genom mätningar ute i fält, vilket är en tidskrävande och ofta kostsam process som gör det motiverat att hitta alternativa möjligheter. Därför undersöker detta examensarbete om digitala kartor och geografisk information, så kallad geodata, istället kan användas för att förutsäga markens bärförmåga, det vill säga markens förmåga att motstå belastningar utan att skadas. Målet med det är att kunna planera skogsavverkning bättre och minska risken för skador utan att behöva vara på platsen som ska undersökas.

Studien bygger på data från 120 provpunkter samlade från sex olika skogsområden runt Uppsala. På varje plats har markens bärförmåga mätts med ett fältinstrument som trycks ned i jorden, en så kallad dynamisk konpenetrometer. Det ger ett mått som kallas California bearing ratio (CBR), ett slags mått som i procent visar hur stark marken är. Ju högre CBR-värde, desto bättre bärförmåga. Den centrala idén med arbetet var att koppla ihop fältmätningar med information från olika typer av digitala kartor. På så sätt undersöks om det går att hitta tydliga samband mellan kartdata och markens verkliga bärförmåga. Om sådana samband finns kan man i framtiden förutsäga markens bärförmåga utan att behöva vara på plats och mäta fysiskt i fält.

En viktig kartvariabel som analyserats är Depth-to-water (DTW)-indexet. Det är en uppskattning av hur långt det är från markytan ner till grundvattnet, och beräknas baserat på höjdkartor och terrängens form. Ju lägre DTW-värde, desto närmare ligger vattnet markytan och desto blötare är marken, vilket innebär lägre bärförmåga. I arbetet analyserades hur olika val vid skapandet av DTW-kartor påverkar förutsägelsen av markens bärförmåga. En viktig inställning som påverkar hur kartorna ser ut kallas för flödesackumuleringströskel. Detta tröskelvärde motsvarar hur stort område som krävs för att ett ytligt flöde ska uppstå. I grunden handlar det om hur mycket vatten som måste samlas upp från omgivningen för att vattnet ska börja rinna på ytan, alltså när ett flöde i landskapet börjar. Det kan liknas vid ett dike, när det regnar lite kan vattnet sjunka ner i marken, men när det samlats tillräckligt mycket vatten börjar det till slut rinna som ett synligt flöde. Tröskelvärdet anger var gränsen går. Ett lågt tröskelvärde innebär att flöden startar lätt vilket motsvarar mycket blöta förhållanden. Ett högt värde innebär att flöden bara uppstår när stora mängder vatten samlats, vilket motsvarar torrare mark. I studien testades flera olika sådana tröskelvärden, från väldigt små områden (0.05 hektar) till mycket större (10 hektar). Resultatet visade att ett värde på 1 hektar gav bäst samband mellan kartan och hur stark marken var enligt CBR-mätningarna.

Ett annat viktigt resultat från studien var att det är bättre att använda kontinuerliga DTW-värden, alltså exakta siffror, snarare än att bara klassa marken som antingen "våt" eller "torr". Det gjorde modellen mer känslig för variationer och förbättrade dess förklaringsvärde nästan dubbelt så mycket. Utöver DTW undersöktes också andra typer av geodata. Bland annat analyserade markens lutning, jorddjup, volymen av skog och torvlagrets mäktighet. När flera av dessa variabler kombinerades i statistiska modeller förbättrades förutsägelserna ytterligare. En särskilt bra

kombination var DTW, lutning och skogens volym, en modell som både var enkel och gav bra resultat. Som en extra del i studien jämfördes även DTW med en annan karta som speglar markfuktighet, SLU:s markfuktighetskarta. Den skiljer sig från DTW på så sätt att den baseras på över 20 olika kartunderlag och beräknas med hjälp av artificiell intelligens (AI). SLU:s karta visade sig vara ännu mer träffsäker än DTW, vilket tyder på att utvecklingen av modeller i framtiden bör använda mer avancerade kombinationer av data.

Sammanfattningsvis visar studien att det är möjligt att förutsäga var marken är mer eller mindre känslig för skogsmaskiner med hjälp av digitala kartor och kartbaserade analyser. Det gör det möjligt att redan i planeringen av avverkningsarbetet identifiera känsliga områden och välja alternativa körvägar, eller att helt undvika platser under blöta perioder. Det gör skogsbruket både effektivare, billigare och mer hållbart. För att modellerna ska fungera optimalt krävs dock fortsatt fältverifiering och noggrann anpassning till de lokala förhållandena.

Ordlista

AIC - Akaike information criterion

CBR - California bearing ratio

DCP - Dynamisk konpenetrometer (eng. Dynamic cone penetrometer)

DEM - Digital höjdmodell (eng. Digital elevation model)

DPI - Penetrationsdjupsindex (eng. Depth penetration index)

DTM - Digital terrängmodell (eng. Digital terrain model)

DTW - Depth-to-water

FIA - Flow initiation area

GIS - Geografiska informationssystem

SGU - Sveriges geologiska undersökning

SLU - Sveriges lantbruksuniversitet

TDR - Tidsdomän reflektometer (eng. Time domain reflectometry)

VIF - Variansinlationsfaktor (eng. Variance inflation factor)

VWC - volymetriskt vatteninnehåll (eng. Volumetric water content)

Markens bärförmåga - Markens förmåga att bära last utan att deformeras eller skadas

Spårbildning - Hjulspår som uppstår när marken inte kan motstå maskinens vikt

Bulkdensitet - Kvot mellan total massa och total volym

Terrängindikator - Variabel härledd från höjddata

Regression av alla delmängder - Regressionsmetod där alla möjliga kombinationer av förklarande variabler testas (eng. All subset regression)

Innehåll

Förord.....	4
Populärvetenskaplig sammanfattning.....	5
Ordlista.....	7
Innehåll.....	8
1 Inledning.....	1
1.1 Bakgrund.....	1
1.2 Syfte och frågeställningar.....	2
1.3 Avgränsningar.....	2
2 Teoretisk bakgrund.....	3
2.1 Markens bärförmåga.....	3
2.1.1 Analyser av bärförmåga.....	3
2.2 Geodata i markundersökningar.....	4
2.3 Statistiska analysmetoder.....	6
3 Material och metod.....	7
3.1 Fältdata från studieområde i Uppsala för att skatta markens bärförmåga.....	7
3.1.1 Mätning markens bärförmåga med DCP-test och CBR.....	8
3.2 Val av alternativa förklarande variabler för prediktion av markens bärförmåga.....	8
3.2.1 Terrängindikatorer.....	9
3.2.2 Markegenskaper.....	10
3.2.3 Vegetation.....	12
3.2.4 Markfukt.....	12
3.3 Databearbetning.....	13
3.3.1 Inkludering av olika lutningsupplösningar.....	13
3.3.2 Framtagning av DTW-kartor för skattning av markfuktighet.....	13
3.3.3 Sammanställning av geodata vid provpunkterna.....	16
3.4 Statistisk analys.....	16
3.4.1 Utvärdering av samband mellan markfaktorer och CBR.....	16
3.4.2 Regressionsmodellering för skattning av markens bärförmåga.....	16
3.4.3 Modellutvärdering/validering.....	17
4 Resultat.....	18
4.1 Samband mellan CBR och geodata.....	18
4.1.1 Påverkan av geodataparametrar för DTW och lutningsberäkning på CBR.....	18
4.1.2 Variablernas samband med CBR och varandra.....	19
4.2 Prediktion av markens bärförmåga med geodata genom regressionsmodellering.....	21
4.2.1 Jämförelse mellan klassificerade och kontinuerliga DTW-data i modeller.....	21
4.2.2 Utökade modeller med fler variabler.....	23
5 Diskussion.....	28
5.1 Tolkning av sambanden mellan markens bärförmåga och geodata.....	28
5.1.1 Effekten av valt tröskelvärde för flödesackumulering på sambandet mellan DTW och bärförmåga.....	28
5.1.2 Hur lutningens upplösning påverkar tolkningen av topografins betydelse.....	28
5.1.3 Tolkning av samband mellan geovariabler och markens bärförmåga.....	29

5.2 Prediktion av markens bärförmåga med geodata.....	30
5.2.1 Fördelar med kontinuerliga DTW-värden för prediktion av bärförmåga.....	30
5.2.2 Hur kompletterande geodata påverkar modellens träffsäkerhet.....	30
5.2.3 Interaktionen mellan jordart och fuktighet i förklaringen av bärförmåga.....	31
5.3 Studiens begränsningar och förslag till framtida forskning.....	32
6 Slutsatser.....	34
Referenser.....	36
Appendix.....	41
Bilaga A. Steg för hydrologisk bearbetning och generering av DTW-karta.....	41
Bilaga B. Samband mellan valda variabler och CBR.....	44

1 Inledning

1.1 Bakgrund

Sverige är ett mycket skogsrikt land med cirka 70% av landets totala yta täckt av skog. Av denna skogsareal är 84% produktiv, vilket gör skogsbruket till en av landets mest betydelsefulla näringar (SCB, 2023). Skogsbruket spelar en central roll för Sveriges ekonomi, sysselsättning och miljömål. Utöver produktionen av virke och biomassa bidrar skogen till viktiga ekosystemtjänster såsom klimatreglering, biologisk mångfald och rekreation. För att säkerställa en långsiktigt hållbar användning av skogens resurser är det avgörande att implementera metoder för hållbar skogsförvaltning (Holmgren, 2021; Angelstam, 2022).

En av de stora utmaningarna inom skogsbruket är att minimera markskador och störningar som uppstår vid exempelvis avverkning. På grund av de senaste årtiondenas mekanisering av skogsbruket har sådana problem blivit större. De markskadorna som uppstår i samband med skogsavverkning är främst markpackning och spårbildning (Ampoorter m.fl., 2010; Heppelmann m.fl., 2022). Markpackning uppstår när skogsmaskiner utövar ett högt tryck på marken, vilket leder till att jordpartiklarna komprimeras. Det resulterar i en minskning av markens porositet och en ökning av bulkdensiteten. Flera faktorer påverkar i vilken utsträckning markpackning uppstår såsom avverkningssystem, antal maskinpassager, terränglutning, jordart och textur, markfuktighet samt skogsskötselåtgärder. Särskilt i områden med låg bärförmåga, dvs områden med hög markfuktighet och fin marktextur, är risken för omfattande skador stor. I dessa områden kan tunga skogsmaskiner orsaka allvarliga skador som kan få långvariga konsekvenser för ekosystemet i skogsmarken (Ampoorter m.fl., 2010).

Markpackning har både kortsiktiga och långsiktiga effekter på skogsmarkens ekosystem och trädens tillväxt. På kort sikt leder komprimeringen av marken till en försämrad syretillgång i jorden, minskad infiltration och ökad ytavrinning, vilket kan orsaka erosion och sedimenttransport. Dessa mekaniska effekter försämrar markens hydrauliska egenskaper och gör det svårare för vatten att tränga ner i jorden (Cambi m.fl., 2015). På lång sikt kan sådana förändringar i markens struktur leda till allvarliga konsekvenser för skogsmarkens ekosystem. En studerad effekt av markpackning är minskad överlevnad och tillväxt hos trädplantor (Naghdi m.fl., 2016). Försämrad markstruktur kan påverka rotsystemets utveckling, vilket i sin tur gör att rötterna är mer mottagliga för patogena svampangrepp (Håkansson, Voorhees och Riley, 1988). På längre sikt kan dessa effekter hämma skogstillväxten och försämma trädens hälsa, vilket reducerar den långsiktiga produktionen av skog.

För att minimera negativa effekter på marken i samband med skogsbruk är det avgörande att planera körstråk och avverkningssvägar utifrån markens bärförmåga och hydrologiska förhållanden. Bärförmåga påverkas av en rad olika miljömässiga och rumsliga faktorer vilka i stor utsträckning kan analyseras med hjälp av Geografiska informationssystem (GIS). GIS är ett dataverktyg som möjliggör insamling, hantering och analys av rumslig och geografisk data och förenklar integrering av flera datakällor för undersökning av samband i landskapet (ESRI, u.å.). Genom GIS kan olika terräng- och miljöindikatorer härledas, som höjd, lutning och jorddjup m.m, vilka ofta är relaterade till markens egenskaper och ger värdefull information. Terrängindikatorer utgår ofta från höjddata och delas in i primära terrängindikatorer, som till exempel lutning, plan- och profilkurvatur eller uppströms avrinningsområde. Genom att kombinera sådana primära indikatorer kan mer komplexa

mått beräknas, så kallade sekundära terrängindikatorer, som exempelvis Depth-to-water (DTW). DTW estimerar det vertikala avståndet mellan markytan och närmaste grundvattenyta och har visat sig vara användbart för att bedöma markfuktighet och därmed även markens bärförmåga (Ågren m.fl., 2014). En annan sekundär indikator är det topografiska våtindexet (TWI, topographic wetness index), vilket också har använts i studier av markfukt men i denna studie bedömdes DTW som mer relevant (Ågren m.fl., 2021). Sådana GIS-härledda terrängindikatorer från digitala höjdmodeller, beskriver landformer som påverkar markfuktighet, dränering och därmed också markens bärförmåga (Echiverri och Macdonald, 2019). Eftersom traditionella fältbaserade undersökningar och provtagningar ofta är tids- och resurskrävande finns ett stort behov av att utveckla modeller som möjliggör tillförlitliga bedömningar av markens egenskaper med hjälp av geodata. Det kan effektivisera planeringen av skogsbruksåtgärder och samtidigt bidra till att minska risken för körskador och andra negativa miljöeffekter (Mohtashami, 2022).

1.2 Syfte och frågeställningar

Syftet med examensarbetet är att undersöka vilka typer av geodata som kan användas för att förbättra prediktionen av markens bärförmåga. Genom att använda GIS-baserade kartor över markfuktighet, jordarter och andra geospatiala variabler, som terrängindikatorer, mark- och vegetationsegenskaper, strävar arbetet efter att utveckla modeller för att skatta markens bärförmåga. Detta arbete bygger på tidigare forskning av Mohtashami m.fl (2023) och syftar till att besvara följande frågeställningar:

1. Förbättras prediktionen av markens bärförmåga om kontinuerliga DTW-värden används istället för klassificerade DTW-värden i modellerna?
2. Hur påverkas modellen när olika tröskelvärden för flödesackumulering vid generering av DTW-kartan används?
3. Vilka alternativa geospatiala variabler uppvisar korrelation med markens bärförmåga och kan användas för att förbättra skattningen av markens bärförmåga?
4. Vilka modeller kan ge den mest tillförlitliga skattningen av markens bärförmåga baserat på geodata?

Genom att besvara dessa frågor hoppas arbetet kunna bidra till utvecklingen av modeller för att skatta markens bärförmåga vilket är av stor betydelse för en förbättrad avverkningsplanering.

1.3 Avgränsningar

Studien är geografiskt avgränsad till sex skogsområden kring Uppsala, vilket begränsar generaliserbarheten till andra regioner med olika mark- och klimatförhållanden. Datainsamlingen genomfördes endast under en vecka i juni 2022, vilket innebär att säsongsvariationer i markfuktighet inte fångats.

2 Teoretisk bakgrund

2.1 Markens bärförmåga

Markens bärförmåga eller styrka avser kapaciteten att hålla och motstå belastningar som appliceras på marken utan att drabbas av deformation såsom spårbildning, skjuvning eller kompaktering (Horn och Fleige, 2011). Inom skogsbruk är bärförmågan särskilt relevant på grund av användningen av tunga maskiner. Maskiner som skördare och skotare med vikter runt 30 och 40 ton fullastade utövar ett högt tryck på marken och kan därför göra stor påverkan (Nordfjell, 2020). Det finns flera olika faktorer som påverkar markens bärförmåga och i skogsmarker är bärförmågan mycket varierande på grund av unika egenskaper såsom tjocka lager av organiskt material och omfattande rotsystem. De främsta faktorerna som bestämmer hållfastheten i skogsmarker är kopplat till fukthalt, jordart, organiskt material och marktyp. Graden av kompaktering beror även på maskintyp, dess vikt samt trafikintensitet (Ampoorter m.fl., 2010). Jordart spelar roll på grund av dess samspel med markfukt där ler- och siltjordar generellt har lägre bärförmåga och är mer känsliga för kompaktering än sandjordar. En finkornig fuktig jord har generellt lägre bärförmåga och större risk att deformeras än en torr grovkornig jord. Jämfört med finkorniga jordar har grovkorniga högre genomsläpplighet och bärförmågan är inte lika påverkad av markens fukthalt. Morän har varierande vattenhållande förmåga beroende av olika sammansättningar. Morän med högre andel finkorniga fraktioner har en högre vattenhållande förmåga. En större andel grus och sand ger en lägre (Nordfjell, 2020; Björnheden m.fl., 2022).

Utöver markfukt och jordart påverkas markens hållfasthet av faktorer som topografi, rotsystem, vegetation och jorddjup. Markens rotsystem och vegetation har betydelse för markens bärförmåga, eftersom rötter stabiliserar jorden och förbättrar dess struktur, särskilt i de övre jordlagret, vilket kan minska erosion och öka markens mekaniska hållfasthet (Zou m.fl., 2024). Vegetation bidrar också till reglering av markfukt och temperatur vilket i sin tur, som tidigare nämnt, har betydelse för markens bärförmåga. Markfukt styrs inte direkt av absolut topografi (höjd eller lutning) utan snarare av terrängens relativa höjd och storleken av uppströms tillrinningsområde. Upphöjda lägen med små tillrinningsområden har ofta mindre tillförsel av vatten och därmed torrare markförhållanden. Eftersom det är svårt att mäta grundvattennivån direkt används terrängindikatorer som tillrinningsområde (ett mått på årsmedelgrundvattenflöde), lutning (kopplat till hydraulisk gradient) och DTW som proxy för att beskriva grundvattennivåns variation i landskapet. Branta sluttningar är kopplade till hög hydraulisk gradient, vilket innebär snabbare dränering och ofta djupare grundvattennivåer. Grundvattennivån påverkar inte markens bärighet direkt, men när grundvatten ligger nära markytan finns ofta ett starkt samband med hög markfukt (Burt och Butcher, 1985; Murphy, Ogilvie och Arp, 2009). Eftersom markfukt påverkar markens mekaniska egenskaper har den därmed betydelse för bärigheten. Sluttningar ökar däremot risken för jordpackning och markglidning eftersom belastningen från maskinerna fördelas över en mindre yta (Kim m.fl., 2025).

2.1.1 Analyser av bärförmåga

För att bedöma markens lämplighet för exempelvis skogsbruksmaskiner krävs en analys av markens bärförmåga, fuktighet och textur vilka kan mätas och bedömas med olika metoder. Markens bärförmåga är avgörande för att säkerställa att tunga maskiner inte orsakar skador på markstrukturen. Två vanliga fältmetoder för att mäta markens styrka är Dynamic Cone Penetrometer (DCP) och Cone Penetration Test (CPT) (Arbianto, Yuono och Gunarso, 2021). Vid

DCP-test trycks en konformad sond ner i marken med hjälp av en hammare som faller från en bestämd höjd. Antalet slag som krävs för att nå ett visst djup registreras och används som mått på markens styrka. CPT innebär att en sond pressas ner i marken med konstant hastighet samtidigt som motståndet kontinuerligt mäts, vilket ger en profil av markens bärförmåga på olika djup. Ytterligare ett test är California Bearing Ratio (CBR), som utvecklats för att kvantifiera markens styrka och styvhet, särskilt för design av vägar och trottoarer. CBR-värdet uttrycks i procent och jämför testmaterialets bärförmåga mot bärförmågan av krossad sten, där ett högre CBR-värde indikerar på starkare mark som kan motstå mer belastning (Arbianto, Yuono och Gunarso, 2021).

Markfukt är en annan kritisk faktor som påverkar markens stabilitet och risken för markskador vid maskinanvändning. Vid fältmätningar används ofta sensorer som mäter volymetrisk vattenhalt (VWC), vilket uttrycker mängden vatten i jorden som en andel av dess volym. Vanliga mätinstrument för att mäta markfukt är tidsdomänreflektometrar (TDR) och kapacitiva sensorer som ger snabba och relativt enkla mätvärden på plats. För mer noggranna analyser kan jordprover samlas in och analyseras i laboratorium där proverna vägs före och efter torkning för att beräkna den exakta vattenhalten. Markfukt påverkas av flera faktorer som nederbörd, avdunstning, vegetationens upptag och jordarternas egenskaper. Upprepade mätningar över tid är ofta nödvändiga för att få en bild över markfuktens variation över året, under olika årstider eller väderhändelser (Björnheden m.fl., 2022; Cherlinka, 2024).

För att bestämma markens textur och mekaniska egenskaper används analyser av kornstorleksfördelning. Förhållandet mellan sand, silt och ler har en stor betydelse för vattenhållande kapacitet, dränering och mekanisk styrka. För att bedöma kornstorleksfördelningen tas fältprover vanligtvis från olika jorddjup och analyseras sedan i laboratorium med hjälp av sällning, för de grövre fraktionerna, och sedimentationsmetoder för finare partiklar.

Analysresultaten redovisas i en kornstorlekskurva som visar fördelningen av partikelstorlekar inom jordprovet. Texturen klassificeras enligt en jordtexturtriangel, där olika proportioner av sand, silt och lera avgör vilken jordart som marken tillhör. Informationen är central för att förstå markens egenskaper, om den är benägen att kompakteras och dess förmåga att dräneras eller hålla fukt. Lera har hög vattenhållande förmåga men låg genomsläpplighet medan sand dränerar snabbt men håller vatten sämre. Därför påverkar kornstorleksfördelningen i hög grad både bärförmågan och markens känslighet för påverkan av skogsmaskiner (Larsson, 2007; SGI, 2023).

Utöver fysiska mätningar i fält kan Geografiska Informationssystem (GIS) användas för att skatta markens egenskaper över större områden. Exempelvis kan markfuktighetskartor skapas med hjälp av högupplösta höjdmodeller baserade på laserdata, som tillsammans med jordartsdata kan ge en indikation på vattenansamling och dränering. GIS kan också kombineras med jordartskartor för att uppskatta marktexturen och därmed indirekt bärförmåga. Dessa geospatiala analyser möjliggör storskaliga planeringar och riskbedömningar utan att varje plats behöver undersökas i detalj i fält. GIS-skattningar är dock beroende av datakvalitet och bör i många fall kompletteras med fältvalidering för att säkerställa att modellerna stämmer överens med verkliga förhållanden (Mohtashami, 2022; Mohtashami, Hansson och Eliasson, 2023).

2.2 Geodata i markundersökningar

Geografiska data utgör en central del i analyser av markförhållanden och används inom en rad olika områden som stads- och infrastrukturplanering samt miljöövervakning (IBM, 2023). Vid markanalyser kan geodata bidra med rumslig information om exempelvis topografi, jordarter, vegetation och hydrologiska förhållanden. Denna information möjliggör modellering av markegenskaper som kan stödja beslutsfattande och bedömning inom en rad olika tillämpningar, däribland skoglig planering och bedömning av markens bärförmåga i samband med avverkning.

Tidigare forskning har visat att markfuktighet och jordarter har ett starkt samband med markens bärförmåga (Uusitalo m.fl., 2019). En vanlig metod för att modellera markfukt är Depth-to-Water (DTW), ett index som uppskattar det vertikala avståndet från markytan till grundvattennivån baserat på topografisk information och ibland även i kombination med kartor av ytvattensystem som till exempel sjöar eller vattendrag. Modellen utvecklad av Murphy, m.fl. (2009; 2011) bygger på digitala höjdmodeller (DEM) och använder hydrologisk terränganalys för att identifiera potentiella vattenflöden i landskapet. Den tar hänsyn till faktorer som höjdskillnader och flödesackumulering för att uppskatta ytvattendrag (bäckar och floder) i landskapet. DTW-indexet har visat sig vara användbart för att förutsäga hydrologiska egenskaper såsom ytvattenflöden och markfuktighet, vilket i sin tur påverkar markens bärförmåga (Schönauer, Väättäinen, m.fl., 2021). Grundprincipen bakom DTW är att vatten rör sig nedåt längs vägen med minst motstånd och flödet påverkas av och kan modelleras med hjälp av topografiska faktorer som terrängens lutning och uppströms dräneringsmönster. I flacka områden eller stora avrinningsområden tenderar grundvattennivån ligga närmare markytan, medan den i branta eller högt belägna områden ofta är djupare till följd av snabbare dränering. På så sätt kan DTW fungera som ett indirekt mått på markfukt där låga DTW-värden antyder fuktmättade förhållanden nära ytan (Ågren, Lidberg och Ring, 2015). I kombination med andra geodata, exempelvis jordarter och vegetation, kan DTW bidra till att identifiera områden med hög risk för låg bärförmåga, vilket är en viktig aspekt vid exempelvis skogsbruksplanering. Noggrannheten i DTW-beräkningen påverkas bland annat av indata såsom höjdmodellens upplösning men också av val i modellens utformning, exempelvis hur vattenflöden initieras och riktas. Dessa faktorer avgör hur väl DTW kan spegla verkliga hydrologiska förhållanden (Qin m.fl., 2011; Ågren, Lidberg och Ring, 2015; Mohtashami m.fl., 2022)

Flera studier har bekräftat DTW som en stark indikator för markens fuktighet och därmed bärförmåga (Oltean, Comeau och White, 2016; Schönauer, Hoffmann, m.fl., 2021; Hoffmann m.fl., 2022). Ågren m.fl. (2014) visade att DTW var en av de bästa prediktorerna för markfuktighet i svenska skogsmarker, med hög noggrannhet mellan DTW och uppmätt fuktighet (som lägst $A_{CC}=80\%$), vilket indikerar dess användbarhet i modellering av markfuktighetsförhållanden. Flera studier har dessutom undersökt sambandet mellan markfuktighet, uttryckt genom DTW-indexet, och förekomst av körskador som hjulspår. Heppelmann m.fl. (2022) observerade i en studie i Norge en hög frekvens av djupa hjulspår i områden med DTW-värden mindre än 1 meter, vilket tyder på svag bärförmåga i dessa områden. Mohtashami m.fl. (2017) undersökte i en svensk studie hur faktorer som DTW, jordart, vägförstärkning och trafikintensitet påverkar risken för hjulspårsbildning vid skogsavverkning. Resultaten visade att DTW-indexet hade en signifikant inverkan på förekomsten av hjulspår i vissa områden, särskilt när det kombinerades med information om jordart. Studien bekräftade att DTW-indexet är en stark indikator för att identifiera fuktiga partier i skogslandskap och därmed användbart vid modellering av markfuktighetsförhållanden.

Jordarternas sammansättning har också visats ha ett starkt samband med markens styrka, ofta uttryckt genom parametrar som CBR eller skjuvhållfasthet. För friktionsjordar som sand och grus är hållfastheten främst relaterad till kornens friktion och graderingsgrad där välgraderat grus kan ha CBR-värden upp till 80%, medan sand har värden runt 10% (Jones, 2017). I kontrast har kohesionsjordar, som lera, generellt lägre CBR-värden, ofta runt 2% och är mer känsliga för variationer i vattenhalt då deras hållfasthet bygger på kohesion och kapillärverkan. Jordar med hög organisk halt, som torvjordar, uppvisar ofta mycket låg bärförmåga främst på grund av materialets höga porositet och kompressibilitet (Nordfjell, 2020).

Utöver DTW och jordartsdata har tidigare forskning också pekat på att andra typer av geodata kan ha betydelse för att förutsäga markens bärförmåga, särskilt genom koppling till markfuktighet och dräneringsförhållanden. Exempelvis har variabler relaterade till vegetation, topografi och klimat och deras samband med hydrologiska eller mekaniska markegenskaper analyserats i vissa studier (Celik m.fl., 2022; Habiboullah och Louly, 2023). Även om dessa variabler inte har studerats i lika stor utsträckning som DTW och jordarter i detta sammanhang kan de utgöra relevanta komplement i geografiska analyser om markens bärförmåga. Det finns därmed ett behov av att vidare undersöka vilka typer av geodata som på ett tillförlitligt sätt kan bidra till att identifiera mark med låg bärförmåga, särskilt i skogliga miljöer där traditionella fältundersökningar är tids- och resurskrävande.

Geodata kan därmed spela en direkt roll i skoglig planering, inte bara för att kartlägga markens egenskaper, utan också för att styra planering av avverkning och skogsbilvägar till platser med högre bärförmåga. Datatyper och lager kan hanteras och integreras i geografiska informationssystem (GIS), vilket möjliggör rumsliga analyser och modellering i stor skala. Genom att integrera exempelvis DTW-modeller, jordartskartor och lutningsdata i GIS kan optimala körvägar som minimerar risken för markskador identifieras. Tillvägagångssättet möjliggör planering, där skotare och avverkningsmaskiner styrs bort från känsliga områden eller används under gynnsammare årstider. Detta kan även användas i maskinförarstödsystem som visualiserar geodata i realtid för att undvika körning på våt eller känslig mark. Resultatet blir ett mer effektivt och hållbart skogsbruk, där behovet av kostsamma markundersökningar i fält minskar och risken för markskador reduceras (Mohtashami, 2011)

2.3 Statistiska analysmetoder

För att undersöka samband mellan olika variabler finns olika statistiska metoder, varav korrelationsanalys och multipel linjär regression (MLR) är två vanliga. Korrelation mäter styrkan och riktningen på sambandet mellan två variabler men säger ingenting om orsak eller verkan. Valet av korrelationsmetod beror på datats egenskaper där Pearsons r används vid normalfördelade, kontinuerliga data och antar linjäritet samt homoskedasticitet (konstant varians i feltermerna). Spearmans rangkorrelation lämpar sig bättre vid icke-parametriska data och när linjäritet och normalfördelning inte kan antas. Multipel linjär regression används för att analysera hur flera förklarande variabler samtidigt påverkar en responsvariabel. Den generella formen för MLR uttrycks som (Helsel m.fl., 2020):

$$y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \varepsilon \quad (1)$$

där y är responsvariabeln, β_0 är interceptet, $\beta_1, \beta_2, \dots, \beta_k$ är regressionskoefficienterna, $X_1, X_2, \dots, X_k$ är de förklarande variablerna och ε representerar feltermen (residualen) som fångar upp den variation som inte förklaras av modellen. Varje koefficient β_i visar hur mycket y förväntas förändras när X_i ökar med en enhet under förutsättning att övriga variabler hålls konstanta (Helsel m.fl., 2020)

För att säkerställa att en MLR-modell är tillförlitlig måste vissa antaganden vara uppfyllda såsom linjäritet, normalfördelade och homoskedastiska residualer samt frånvaro av stark korrelation mellan de förklarande variablerna (multikollinearitet). Dessa antaganden kontrolleras bland annat genom residualanalys, Q-Q-diagram och Variance Inflation Factor (VIF). Val av förklarande variabler sker ofta genom stegvisa metoder eller med regression av alla delmängder (All Subset Regression), där målet är att hitta en så enkel modell som möjligt med god förklarings- och prediktionsförmåga. Modellutvärdering görs med mått som R^2 (andelen variation som förklaras av modellen), justerat R^2 (justerat för antalet förklarande variabler), Akaike Information Criterion (AIC), Bayesian Information Criterion (BIC) och Mallows C_p som beskrivs mer detaljerat i Helsel m.fl. (2020). Prediktionsförmåga kan även utvärderas med korsvalidering.

3 Material och metod


Denna sektion beskriver den stegvisa metod som tillämpades för att undersöka sambanden mellan olika geodata och markens bärförmåga, uttryckt som CBR. Studien kombinerade geografisk dataanalys (GIS), fältbaserad datainsamling, statistisk analys och regressionsmodellering för att utveckla prediktiva modeller för markens bärförmåga.

3.1 Fältdata från studieområde i Uppsala för att skatta markens bärförmåga

Grunden för analysen utgjordes av fältdata som samlats in i en tidigare studie (Mohtashami m.fl. 2023) där GIS-baserade kartor som DTW-markfuktighetskartor och SGU:s jordartskartor användes för att prediktera markens bärförmåga. Mätningarna genomfördes i skogsmarker runt Uppsala, Sverige (17.7961541° E, 59.8905069°) under 7 dagar i juni 2022, se figur 1. Enligt Köppen-Geiger-systemet har Uppsala ett varmt tempererat klimat (Cfb) med tydliga säsongsvariationer. Den genomsnittliga årsnederbörden uppgår till 626 mm och den årliga medeltemperaturen till 6.8 ° C i området enligt SMHI:s referensdata för perioden 1991-2020 (SMHI, 2025). Under juni 2022 var medeltemperaturen 17,8° C och nederbörds mängden 51 mm, vilket var cirka 20 % lägre än det historiska normalvärdet för samma månad enligt referensdata för perioden 1991-2020 (SMHI, 2025). Skogarna i Uppsala län består främst av barrskog och marken består huvudsakligen av lera-silt, isälvs material och morän (SGU, 2023; Naturskyddsföreningen, 2025).

Fältmätningarna omfattade 120 provpunkter, uppdelade på tre jordtyper (ler-silt, sand samt morän) och två fuktighetsklasser (våt och torr). Jordartsklassificeringen baserades på SGU:s uppdaterade jordartskartor (skala 1:25 000 - 1:100 000). Markfuktigheten klassificerades med hjälp av Depth-to-Water (DTW)- kartor från Skogsstyrelsen (2 meters upplösning) med ett tröskelvärde på 1 meter för indelning av våt ($DTW \leq 1m$) eller torr ($DTW > 1m$) mark. Vid varje provpunkt utfördes följande mätningar:

- Dynamisk konpenetrometer (DCP) test för beräkning av California Bearing Ratio (CBR)
- Volymetrisk vattenhalt (VWC) med en Time Domain Reflectometry (TDR)-mätare
- Penetrationsdjup (mm) med hjälp av en Haglöfs jordsond
- Djup av moss- och humuslager (cm)
- Jordprov för laboratorieanalys



Figur 1. Karta över studieområdet i Uppsala med mätpunkter för fältundersökningen utplacerade som röda punkter i figuren.

3.1.1 Mätning markens bärförmåga med DCP-test och CBR

I studien beräknades markens bärförmåga genom att mäta och analysera California Bearing Ratio (CBR) med hjälp av en dynamisk konpenetrometer (DCP). DCP-test utfördes genom att penetrera marken med en kon efter att det översta moss- och humuslagrets avlägsnats. Testet fortsatte tills ett penetrationsdjup på minst 200 mm hade uppnåtts. För varje provpunkt beräknades ett penetrationsdjupsindex (DPI), definierat som konens nedsänkning per hammerslag (mm/slag). Detta index användes för att uppskatta markens bärförmåga vid varje provpunkt, uttryckt som CBR per hammerslag, enligt:

$$\log(CBR) = 2.46 - 1.12 * \log(DPI) \quad (2)$$

där DPI representerar penetrationsdjupsindexet (mm/slag). För varje punkt beräknades ett medelvärde av CBR för de översta 200 mm som användes som responsvariabel i de efterföljande analyserna.


3.2 Val av alternativa förklarande variabler för prediktion av markens bärförmåga

För att undersöka vilka variabler som kan korrelera med bärförmågan i skogsmark har ett urval av geospatiala variabler analyserats. Valet av variabler baserades på den förväntade kopplingen till markens fysiska egenskaper, fuktighet, stabilitet och vegetation, samt tillgången på geodata med god täckning och upplösning. Variablerna representerar fyra övergripande kategorier: terrängindikatorer, markegenskaper, vegetation samt markfuktighet. Fältdata i form av CBR-mätningar med koordinater för 108 provpunkter som erhöles från den tidigare studien låg till grund för modelleringen. Av de ursprungliga 120 provpunkterna inkluderades endast 108 punkter i denna studie på grund av att 12 punkter var belägna på stenig mark där CBR-mätningar inte kunde genomföras och inga CBR-värden erhöles. Även fältbestämda jordarter inkluderades i analysen. Fältdata kompletterades och förklarande variabler extraherades från relevanta rasterlager från Skogsstyrelsen, Lantmäteriet och Sveriges geologiska undersökningar (SGU). All data bearbetades och analyserades i ArcGIS Pro.

3.2.1 Terrängindikatorer

De tre valda terrängindikatorerna var: *Depth-to-water (DTW)*, *lutning* och *höjd över havet*. DTW beskriver det beräknade vertikala avståndet mellan markytan och grundvattnet, där låga värden indikerar större sannolikhet för blöt mark. Figur 2 illustrerar en DTW-karta framtagen över studieområdet. Valet av topografi motiverades för att det är en viktig faktor som påverkar markens dränering, fuktighet och därmed bärförmåga. Lutning påverkar både vattenavrinning och maskiners framkomlighet, där brantare sluttningar innebär snabbare förändring i vattennivå över ett visst avstånd. Det finns generellt inget tydligt samband mellan absolut höjd och uppströms avrinningsyta, och dessutom kan avrinningsytor beräknas direkt från en digital höjdmodell. Därför förväntas inte höjd ensam ha stor potential att prediktera markfukt, särskilt inte i ett relativt litet studieområde som detta. I denna studie inkluderades höjd ändå i analysen för att undersöka om den kan bidra med kompletterande information till modellen. Upphöjda områden med små tillrinningsområden har ofta mindre vattentillförsel och därmed torrare förhållanden, även om höjdskillnaderna i området är små och ett starkt samband därför inte förväntas. Samtliga dessa variabler härleddes från Lantmäteriets markhöjdmodell Grid 1+, ett rasterunderlag med 1 meters upplösning. Laserskanning av marken skapar ett punktmoln av returpelserna som klassificeras som mark- eller icke markpunkter (som vatten, infrastruktur, byggnader, vägar m.m) där markpunkterna sedan används för att skapa en digital terrängmodell (DTM). Koordinatsystemet för underlaget är SWEREF99TM i plan och RH 2000 i höjd. Kartan är rikstäckande och uppdateras kontinuerligt (Lantmäteriet, 2023). Data bearbetades till DTW och lutning genom topografisk analys, medan höjd hämtades direkt från den digitala markhöjdmodellen (DEM).


Det är värt att notera att det finns ett brett spektrum av andra terrängindikatorer som kan användas för att karaktärisera landskapets hydrologiska och topografiska egenskaper såsom plan- och profilkurvatur, topografiskt våtindex (TWI), exponering (aspect) och relativ höjd (Qin, C.-Z. m.fl., 2011). Dessa kan ge ytterligare insikt om lokala variationer i markfukt och dränering. I denna studie begränsades dock valet för att avgränsa studiens omfattning och därför fokuserade studien på ett urval som tidigare visat starka samband med markfukt och bärförmåga. De valda indikatorerna ansågs därför ge tillräcklig och relevant information för att besvara studiens syfte.



Figur 2. DTW-karta över studieområdet som visar djup till grundvattnet i meter. Mörka områden indikerar grundvatten nära markytan. Kartan är framtagen från en höjdmodell med 1 meters upplösning med ett FIA-tröskelvärde på 1 hektar.

3.2.2 Markegenskaper

Inom markegenskaper valdes tre variabler: *jorddjup*, *torvlagrets mäktighet* samt *jordart*, se figur 3 för exempelkartor över studieområdet. Jordart och jorddjup valdes för att de direkt påverkar markens mekaniska egenskaper, såsom bärighet och vattenhållningsförmåga. Finkorniga jordarter som lera har ofta sämre bärighet än exempelvis sand eller morän. Jorddjupet avgör hur mäktigt det lösa jordlagret är ovan berg vilket kan påverka både vattenflöden och markstabilitet. För att ta hänsyn till ytligt organiskt material användes också tjockleken på torvlagret som en separat variabel. Jordarter hämtades från SGU:s jordartskarta i skalan 1:25 000–1:100 000, vilken visar de översta 50 cm av markprofilen och bygger på fältinventering, provtagning och flygbildstolkning. Det innebär att kvaliteten både vad gäller lägesnoggrannhet och klassificering av jordarter kan variera beroende på metod och täckningsgrad (SGU, 2024a). Jorddjupet togs från SGU:s jorddjupsmodell med 10 meters upplösning med jorddjupen angivna i meter, vilken bygger på interpolation av bland annat brunnborrningar, seismik och jordartsinformation. På grund av varierande avstånd till närmaste observation kan osäkerheten i beräkningarna variera (SGU, 2024b). För att kvantifiera torvlagrets mäktighet användes SLU:s kontinuerliga torvkarta som visar tjockleken på det organiska lagret i centimeter, baserad på AI-modeller tränade på data från nationell markinventering och markfuktighetskartor. Formatet är rasterdata med upplösning på 2x2 meter och koordinatsystemet för alla tre underlagen är SWEREF99TM (SLU, 2024).




Figur 3. Översiktskarta över studieområdet baserad på tre olika geodataunderlag. Övre vänster: Jorddjupet i meter från SGU:s jorddjupsmodell. Övre högre: Torvlagrets djup i meter, baserat på kartmaterial från Institutionen för skogens ekologi och skötsel, SLU. Nedre: Jordarter enligt SGU:s produkt *Jordarter 1:25000-100000*. Källor: © SLU, ©SGU (CC0).

3.2.3 Vegetation

En vegetationsvariabel användes: *volym av virkesförrådet i skogskubikmeter per hektar* ($\text{m}^3\text{sk/ha}$). Ett högt virkesförråd kan indikera en väletablerad skog med stabiliserande rotsystem och även innebära hög belastning vid avverkning. Virkesförrådet hämtades från Skogsstyrelsens produkt Skoglig grunddata, där kartskiktet är baserat på Lantmäteriets nationella laserskanning och provytor från Riksskogstaxeringen vid SLU. Se figur 4 för kartunderlaget över studieområdet. Upplösningen


på underlaget är 10x10 meter och uppdateras kontinuerligt utefter när ny laserskanningsdata produceras. Noggrannheten är högre i barrskog än i lövskog och beroende på när laserskanningen skett (med eller utan löv på träden) varierar noggrannheten. Koordinatsystemet för underlaget i plan är SWEREF99TM och i höjd RH 2000 (Skogsstyrelsen, 2025).



Figur 4. Virkesförråd i studieområdet ($\text{m}^3\text{sk/ha}$), baserat på Skogsstyrelsens skoglig grunddata. Källa: ©Skogsstyrelsen (CC0)

3.2.4 Markfukt

Slutligen ingick *markfukt* som en variabel då det är direkt kopplat till markens bärighet. Markfukten representerades genom SLU:s kontinuerliga markfuktighetskarta, där varje pixel ges ett värde mellan 0 (torr) och 100 (blöt). Värdena beskriver medelmarkfuktigheten för en rastercell under året. Kartan är uppdelad i färger där röda områden symboliserar torr jord, gula områden frisk jord, gröna områden färskfuktig jord och turkosa och blå områden fuktig jord, se figur 5. Kartan är framtagen med hjälp av maskininlärning och bygger på ett stort antal underlag (24 kartor), bland annat terrängindikatorer, hydrologisk data och fältdata från nationella markinventeringen. I blå/turkosa områden kan jorden till stora delar av året förväntas vara blöt/fuktig och gröna områden ha mer fuktvariation under året. Gröna och blåa områden kan därför anses vara mer känsliga, vilket kan vara användbar information inom skogsavverkningsplanering. Kartan bygger på hydrologiska modelleringar baserat på Lantmäteriets höjddata grid 2+ och har en upplösning på 2x2 meter. Koordinatsystemet är SWEREF99TM (SLU, 2020; Ågren, 2023).



Figur 5. SLU:s kontinuerliga markfuktighetskarta över studieområdet. Färgerna representerar olika markfuktighetsklasser: röda områden = torr mark, gula = frisk mark, gröna = färskfuktig mark, turkosa och blå = fuktig mark. Röda punkter markerar mätpunkter. Källa: ©SLU Markfuktighetskarta, Institutionen för skoglig ekologi och skötsel, SLU.

3.3 Databearbetning

3.3.1 Inkludering av olika lutningsupplösningar

Från den ursprungliga markhöjdmodellen med 1 meters upplösning beräknades ett lutningslager i ArcGIS Pro med hjälp av Spatial Analyst-verktyget *Slope*. Eftersom en högupplöst DEM ger detaljerade lutningsvärden som inte fångar lutningstrender över större områden resamplades DEM:en till flera upplösningar (10, 20, 50, 70, 80 och 100 meter) med verktyget *Resample*. Utifrån de nya höjdlagren beräknades nya lutningslager för alla upplösningar i syfte att analysera hur rumslig upplösning påverkar sambandet mellan lutning och CBR.


3.3.2 Framtagning av DTW-kartor för skattning av markfuktighet

För att uppskatta markfuktigheten i studieområdet användes DTW-indexet som skapades utifrån den digitala höjdmodellen DEM. DTW-modellen bygger ett raster som representerar det vertikala djupet från varje pixel i terrängen till närmaste härledda ytvattenflöde. Varje cell i rastret representerar då ett specifikt djup till grundvattnet vid den platsen.

Innan generering av Depth-To-Water (DTW)-kartan förbehandlades den digitala höjdmodellen (DEM) för att möjliggöra en korrekt vattenflödesmodellering och säkerställa ett kontinuerligt flöde. Digitala höjdmodeller från laserskanning innehåller ofta artificiella sänkor eller hinder som kan störa det naturliga vattenflödet och därmed leda till felaktiga flödesackumuleringar.

Förbehandlingen kan göras med hjälp av spatiala verktyg som exempelvis Whiteboxtools eller verktyg i GIS (Lindsay, 2014). I detta arbete användes en hydrologisk bearbetningsmetod, som kombinerar att fylla sänkor, gräva kopplingar mellan sänkor och jämna ut markens yta, som tidigare visat sig ge ett mer realistiskt flödesmönster än vid endast fyllning av sänkor (White m.fl., 2012;

Fastrup, 2024). Verktöget *Breach Single Cell Pits* användes för att identifiera och korrigera så kallade sänkor genom att gräva kopplingar mellan dem. Därefter fylldes eventuella sänkor genom verktöget *Fill Single Cell Pits* som identifierar celler som är lägre än de runt omkring och fyller dem för att få en mer realistisk terräng. Verktöget *Feature Preserving Smoothing* användes för att jämna ut höjdmodellen för att minska brus och små variationer. Till sist användes *Breach Depressions Least Cost* för att hantera kvarvarande sänkor som uppstår över större områden. Sådana sänkor kan orsaka problem eftersom vattnet tenderar att samlas där vilket blockerar flödet. Metoden använder så kallat “least cost” för att bryta dessa sänkor och skapa det mest naturliga flödet (Lindsay, 2016). Se appendix bilaga A, Tabell 2 för de verktyg som användes för den hydrologiska bearbetningen med input, output och använda parametrar. Från den hydrologiskt bearbetade DEM:en genererades en Depth-to-Water (DTW)-karta enligt stegen som illustreras i figur 6.




Figur 6. Schematisk beskrivning av stegen som använts för att generera DTW-kartan.

DTW-indexet beräknades med hjälp av geospaciala verktyg i ArcGIS Pro (se figur 6) tillsammans med den bearbetade markmodellen. Först beräknades flödesriktningar med D8-algoritmen (enkla riktningar) följt av flödesackumulering för att identifiera var vatten sannolikt samlas i landskapet. För att härleda flödeslinjer tillämpades ett tröskelvärde, så kallat Flow Initiation Area (FIA), på flödesackumuleringsrastret. Tröskelvärdet definierar det minsta antalet uppströms celler, även kallat upstream accumulation area (UAA), som krävs för att ett vattenflöde ska initieras i en cell och att en cell ska klassas som en vattenflödeskanal. Detta tröskelvärde är centralt eftersom det motsvarar den punkt där markens hydrauliska ledningsförmåga, i kombination med lutningen, inte längre kan ta allt vatten som grundvattenflöde. Vid höga UAA kan överskottsvatten därför börja rinna av nära markytan, vilket innebär att ett ytligt flöde uppstår. En korrekt definiering av tröskelvärdet blir avgörande för att realistiskt återge var tillfälliga strömflöden bildas i landskapet och valet av FIA-värde bör anpassas efter syftet med modellen och den rumsliga skalan på analysen (Ågren, Lidberg och Ring, 2015). Ett lågt FIA-värde resulterar i ett finförgrenat nätverk av flödeskanaler medan ett högre värde endast fångar upp större huvudflöden. Rasterlagret med flödeskanaler konverterades sedan till ett vektorlager och från DEM:en beräknades lutning som sedan konverterades från grader till radianer med hjälp av verktöget *Raster calculator*. Slutligen beräknades DTW som den minsta kostnadsvägen (least-cost-path) från varje cell till närmast identifierade flödeskanal, där kostnaden är en funktion av lutning och cellstorlek längs vägen enligt (Murphy m.fl., 2009):

$$DTW = [\sum(\frac{dz_i}{dx_i}a)]x_c \quad (3)$$

med $\frac{dz_i}{dx_i}$ som motsvarar lutningen för cell i längs den lägsta kostnadsvägen, $a = 1$ för horisontell och $a = \sqrt{2}$ för diagonal riktning över cellen, x_c är cellstorleken för höjdmodellen. Detta resulterade i kontinuerliga DTW-värden som skattar markens fuktighet. Låga DTW-värden indikerar att grundvattnet ligger nära markytan, vilket ofta sammanfaller med hög markfuktighet. De geospatiala verktygen med input, output och parametrar som användes för att generera DTW-kartan presenteras i appendix bilaga A (tabell 2).

För att representera olika hydrologiska förhållanden skapades flera DTW-kartor med varierande FIA-tröskelvärde. Som utgångspunkt användes ett tröskelvärde på 1 hektar vilket motsvarar fuktiga förhållanden (Karjalainen, Malinen och Tokola, 2024). Därefter skapades flera olika DTW-kartor med tröskelvärden på 0.05, 0.1, 0.3, 0.5, 2, 3, 4, 5, 7 och 10 hektar. Där 0.05 hektar motsvarar mycket fuktiga markförhållanden, som vid snösmältning i början av våren eller efter perioder med kraftig nederbörd, till exempel i slutet av hösten och 10 hektar motsvarar mycket torra förhållanden. Detta gjordes för att undersöka känsligheten av olika tröskelvärden i prediktionsmodellen. Värdet ändrades i verktyget *Set Null* vilket skapade rasterlager med olika utbredning av flödeslinjer, se figur 7. Figuren illustrerar att ett lägre tröskelvärde representerar fuktigare markförhållanden och ett mer utbrett flödesnätverk än ett högre tröskelvärde.



Figur 7. Jämförelse av flödeslinjernas utbredning baserat på olika tröskelvärden för flödesackumulering. Lägre tröskelvärden resulterar i ett tätare flödesnätverk som representerar våtare markförhållanden.

3.3.3 Sammanställning av geodata vid provpunkterna

Alla geografiska variabler extraherades runt provpunkternas koordinater från ArcGIS Pro. För kontinuerliga raster användes verktyget *Zonal statistics as Table*, där ett medelvärde beräknades inom en buffertzona på 10 meters radie runt varje mätpunkt. För kategoriska data baserades extraktionen på majoritetstäckningen inom varje buffert.

3.4 Statistisk analys

3.4.1 Utvärdering av samband mellan markfaktorer och CBR

All statistisk analys genomfördes i programmeringsspråket Python (version 3.10.11) i Thonny (version 4.1.7) med bibliotek såsom Pandas, Numpy, Scipy, Matplotlib och Statsmodels. Efter att ha tagit bort observationer med saknade värden genomfördes beskrivande statistik. Därefter beräknades Spearman-korrelationer mellan alla variabler vilket visualiserades i en pairplot och korrelationsmatris. Spridningsdiagram mellan CBR och varje enskild variabel användes för att undersöka mönster. Hög korrelation och ett logaritmiskt samband upptäcktes i korrelationsanalysen mellan torvlagrets mäktighet (P) och DTW (DTW1) vilket motiverade att inte inkludera båda dessa variabler i samma modell.

3.4.2 Regressionsmodellering för skattning av markens bärförmåga

De valda variablerna för vidare analys med regressionsmodellering var: *Klassificerad DTW (DTW)*, *klassificerad jordart från kartor (JAm)*, *klassificerad fältbestämd jordart (JAf)*, *kontinuerlig DTW från tröskelvärde på 1 hektar (DTW1)*, *markfukt från SLU:s markfuktighetskarta (MF)*, *lutning från upplösning på 70 meter (L70)*, *virkesförråd (VF)*, *torvdjup (TD)* och *jorddjup (JD)*.

Efter den inledande statistiska analysen genomfördes regressionsanalyser med multipel linjär regression i flera steg med log-transformerade CBR-värden som responsvariabel. Arbetet har utgått från Mohtashami m.fl. (2023) studie och målet var att undersöka vilka alternativa geospatiala variabler som påverkar markens bärförmåga, samt om dessa variabler kan förbättra skattningen av bärförmågan. Därför utvecklades en basmodell som replikerade modellen i den tidigare studien enligt:

$$\log_{10}(CBR) = \beta_0 + \beta(DTW_{klass} \times JA) + \varepsilon \quad (4)$$

med β_0 skärningen, β regressionskoefficienten och ε residualerna. Denna modell med klassificerade (våt och torr) DTW- och jordartsvärden (sand, morän och ler-silt) som förklarande variabler användes som jämförelse och referens för övriga modeller. Baserat på resultat från tidigare studier som tyder på att effekten av *DTW* på markens bärförmåga beror av jordart inkluderades interaktionstermen $DTW \times JA$ som en grundkomponent i alla primära modeller. På grund av hög korrelation mellan *torvdjup* och *DTW* inkluderades inte båda variablerna i samma modell men eftersom *torvdjup* uppvisade en starkare korrelation med *CBR* jämfört med *DTW* utvecklades även modeller där *DTW* ersattes med *torvdjup*. Variabeln *jordart* kodades som en kategorisk variabel med dummyvariabler för respektive jordart (sand, morän, ler-silt). Därefter testades basmodellen med kontinuerliga DTW-värden istället för klassificerade. Även en modell för varje jordart var för sig utvecklades för att bedöma modellens prestanda vid olika typer av jordar.

För att utvärdera de alternativa variablernas prediktionsförmåga byggdes först en utökad modell som inkluderade basmodellen tillsammans med samtliga övriga valda variabler. Multikolinjäritet kontrollerades genom att beräkna Variance Influence Factor (VIF) och variabler med $VIF > 5$ togs bort ur modellen. Därefter genomfördes regressionsanalys för alla delmängder (s.k. All subset regression på engelska) för att identifiera de mest relevanta variablerna och interaktionerna för att förklara variationen i $\log(CBR)$. Analysen byggde på ett iterativt tillvägagångssätt i tre steg. I det första steget användes basmodellen som utgångspunkt, och en variabel i taget lades till. För varje antal inkluderade variabler testades alla möjliga kombinationer, men endast de två modeller som

presterade bäst baserat på justerat R^2 , R^2 och Akaike Information Criterion (AIC) sparades till tabellen (tabell 1). Ett p-värde på 0.05 valdes för att identifiera signifikanta faktorer i modellerna. I det andra steget användes en tom modell som utgångspunkt, det vill säga en modell utan några förklarande variabler inkluderade till en början, för att undersöka varje enskild variabels bidrag till modellens förklaringsvärde utan närvaro av interaktionstermen. Alla variabler lades till en och en, utan interaktionstermer, för att avgöra vilka som ensamma kunde förbättra modellens prestanda. I det tredje och sista steget användes återigen en tom modell som startpunkt, men denna gång tilläts även alla möjliga interaktioner mellan variabler som prediktorer. Eftersom detta leder till ett stort antal möjliga modellkombinationer, användes ett automatiserat Python-skript för att systematiskt testa samtliga tänkbara kombinationer. För varje antal inkluderade variabler sparades enbart de två bäst presterande modellerna baserat på ovan nämnda kriterier. Denna procedur möjliggjorde ett objektiva och heltäckande urval av de mest informativa variabelkombinationerna, utan att resultatet styrdes av subjektiva val.

Slutligen genomfördes känslighetsanalyser för att undersöka modellernas beroende av datakällornas egenskaper. Två olika jämförelser gjordes, den första genom att byta ut DTW-värden mot värden från SLU:s markfuktighetskarta. SLU:s karta har ett rikare informationsinnehåll eftersom den, till skillnad från DTW som baseras enbart på topografi, även inkluderar faktorer som bland annat jordart och hydrologisk data (Ring m.fl., 2021). Den andra var genom att ersätta GIS-baserade jordarter med jordarter bestämda från fältmätningar, eftersom den kartbaserade jordartskartan är mer översiktligt och kan innehålla avvikelser jämfört med verkliga förhållanden, vilket även noterades i studien.

3.4.3 Modellutvärdering/validering

Samtliga modeller utvärderades med residualanalys genom att kontrollera residualernas normalfördelning med Q-Q plot och homoskedasticitet med residualdiagram. Modellerna jämfördes utifrån förklaringsgrad (justerat R^2).


I regressioner med alla delmängder användes AIC som kriterium för att bedöma den relativa passformen för varje modell. Dessutom kontrollerades justerat R^2 och R^2 för att undersöka om inkluderingen av ytterligare variabler eller interaktioner ledde till meningsfulla förbättringar av modellen. De två bästa modellerna för varje antal av förklarande variabler sparades och utvärderades, baserat på R^2 , och den bästa modellen valdes baserat på justerat R^2 som tar hänsyn till olika antal förklarande variabler.

4 Resultat

4.1 Samband mellan CBR och geodata


4.1.1 Påverkan av geodataparametrar för DTW och lutningsberäkning på CBR

Den första analysen fokuserade på att undersöka hur valet av tröskelvärde för flödesackumulering (FIA-värde) påverkade sambandet mellan DTW och CBR. Tröskelvärdet avgör hur stort det uppströms ackumulerade avrinningsområdet måste vara för att ett flöde ska initieras, vilket påverkar DTW-beräkningen. För att hitta det mest informativa tröskelvärdet beräknades DTW med flera olika tröskelvärden och korrelationen med CBR jämfördes. Figur 8 visar sambandet mellan korrelation och tröskelvärden. Figuren visar att korrelationen ökade från cirka 0.2 vid mycket låga tröskelvärden till en topp vid tröskelvärdet 1 hektar, med ett korrelationsvärde på cirka 0.37. Tröskelvärden mellan 0.5 och 3 hektar uppvisade snarlika korrelationer (cirka 0.32-0.37) men därefter minskade sambandet tydligt med den lägsta korrelationen för 10 hektar (cirka 0.1). Baserat på dessa resultat valdes DTW-data genererade med ett tröskelvärde på 1 hektar för vidare analyser, eftersom detta värde visade den starkaste korrelationen med CBR. Det bör noteras att detta tröskelvärde inte ska förväxlas med det DTW-tröskelvärde som användes (1 meter) för att klassificera marken som våt eller torr i den kategoriska DTW-variabeln.



Figur 8. Korrelationen mellan olika tröskelvärden för flödesackumulering i DTW-beräkningen och CBR-värden. Den starkaste korrelationen nås vid tröskelvärde på 1 hektar.

I nästa steg analyserades hur upplösningen på lutningsdata påverkade sambandet med *CBR*. I figur 9 ses att korrelationen var relativt stabil mellan upplösningar på 20-80 meter (cirka 0.29-0.31) med en tydlig topp vid 70 meter (över 0.32). Vid lägre upplösningar (100 meter) sjönk korrelationen markant till cirka 0.23. De medelfina upplösningarna gav bäst precision att fånga den topografiska påverkan på markens bärförmåga och i vidare analyser användes lutningsvärden från en upplösning på 70 meter baserat på korrelationsanalysen.




Figur 9. Korrelationen mellan olika upplösningar på lutningsrastret och *CBR*. Den starkaste korrelationen nås vid en upplösning på 70 meter.


4.1.2 Variablernas samband med *CBR* och varandra

Från Spearman's korrelationsmatris, figur 10, ses att korrelationen mellan *höjdvärden* (*H*) och *CBR* är 0.01, vilket speglar ett mycket svagt samband. Det tyder på att *höjd över havet* inte direkt hjälper till att förklara variationen i *CBR* och därför inte bör inkluderas i modellen. Eftersom lutning härleds från höjddata och sannolikt har bättre prediktiv förmåga av markens bärförmåga fångas effekten av *höjdvärden* delvis av lutningsvariabeln och *höjd över havet* kunde uteslutas ur modellen. Av matrisen framgår även att markfukt hade stark negativ korrelation med *CBR* ($\rho=-0.42$). *Torvdjup* (*TD*) visade också en tydlig negativ korrelation med *CBR* ($\rho=-0.44$). *Virkesförråd* (*VF*) korrelerade svagare negativt med *CBR* ($\rho=-0.22$). *DTW* (*DTW1*) hade den starkaste positiva korrelationen med *CBR* ($\rho=0.37$), även *lutning* (*L70*) visade ett positivt samband med *CBR* ($\rho=0.32$). *Jorddjup* visade relativt svag positiv korrelation med *CBR* ($\rho=0.16$). I pairplot-figuren (figur 11) illustreras att sambandet mellan *CBR* och *jorddjup* (*JD*) tydligt varierar beroende på marktyp. För sand ökade *CBR* med *JD*, medan sambandet var svagt eller negativt för morän och ler-silt. Liknande mönster ses mellan *DTW1* och *CBR*. Mellan *CBR* och *virkesförråd* (*VF*) är sambandet för sand istället negativt. En tydlig outlier i *CBR*-värde omkring 50 noteras. Figur 11 illustrerar endast ett urval av variablerna medan en pairplot med alla valda variabler ses i Appendix bilaga B (figur 16). Ur figuren i bilaga B visas ett tydligt icke-linjärt samband mellan *DTW1* och *TD* med ett logaritmiskt mönster. *Torvdjupet* är generellt högre vid lägre *DTW*-värden (ytligt grundvatten) och minskar

snabbt när DTW ökar för att stabilisera sig vid relativt låga värden. Även korrelationsmatrisen visar ett starkt negativt samband mellan *TD* och *DTW1* (-0.81).



Figur 10. Spearmans korrelationsmatris som visar spearmans rho (ρ) rangkorrelation mellan alla valda variabler. Större negativt eller positivt värde tyder på en starkare korrelation där 1 representerar ett perfekt samband. Signifikanta korrelationer representeras av *.




Figur 11. Pairplot-figur med parvisa jämförelser mellan utvalda variabler: *California bearing ratio* (CBR), *Depth-to-water* (DTW1), *virkesförråd* (VF) och *jorddjup* (JD). Diagonalplottarna visar fördelningen av mätvärden för respektive variabel, medan övriga plottar visar spridningsdiagram med linjära regressionslinjer och tillhörande 95 % konfidensintervall (skuggade områden). Figuren visualiserar möjliga samband mellan olika variabler samt hur dessa skiljer sig mellan olika jordarter (färgkodat utifrån klassificerad jordart (sand, ler-silt och morän)).


4.2 Prediktion av markens bärförmåga med geodata genom regressionsmodellering

4.2.1 Jämförelse mellan klassificerade och kontinuerliga DTW-data i modeller

Den första modellen, basmodellen som replikerade modellen i den tidigare studien (Mohtashami m.fl. 2023) med klassificerade DTW- och jordartsvärden som förklarande variabler, resulterade i en modell som var signifikant ($p=0.0422$) med ett lågt R^2 -värde på 0.104. Huvudeffekten av *DTW_torr* var signifikant ($p=0.004$) och hade ett positivt samband med responsvariabeln ($\beta=0.3573$), vilket betyder att torrare mark har högre $\log(CBR)$ värden jämfört med referens kategorin (*DTW_blöt*). Den övergripande modellens passform var dock relativt svag med ett justerat R^2 -värde på 0.062. Residualerna för modellen visade vertikala mönster (figur 12) vilket motsvarar de två klassificerade variablerna i modellen. Trots mönstret i residualdiagrammet visade Q-Q plotten (figur 13) att residualerna mestadels följde normalitetslinjen, dock med viss avvikelse i båda svansarna. Modellekvation med ingående variabler och regressionskoefficienter ses i appendix bilaga C (tabell 3, ekvation (5)).




Figur 12. Residualdiagram för regressionsmodell med klassificerade DTW- och jordartsvariabler. Det vertikala mönstret tyder på påverkan av klassificerade variabler.




Figur 13. Q-Q plot för regressionsmodell med klassificerade DTW- och jordartsvariabler. Visar avvikelser från normalitet i residualernas fördelning, med viss avvikelse i svansarna.

Den andra modellen med kontinuerliga DTW-värden (från ett tröskelvärde på 1 hektar) erhöll ett R^2 -värde på 0.194 och justerat R^2 på 0.155, vilket innebär en förbättring i förklarande förmåga. Den kontinuerliga DTW-variabeln hade en stark positiv och signifikant effekt på responsvariabeln ($\beta = 0.0915$, $p < 0.001$). Interaktionstermen var inte statistiskt signifikant. Residualplotten (figur 14) visade mer homogen spridning, vilket tyder på att modellantagandena är uppfyllda. På liknande sätt följde Q-Q diagrammet normalitetslinjen relativt väl, återigen med viss avvikelse i svansarna (figur 15). Modellekvation med ingående variabler och regressionskoefficienter ses i appendix bilaga C (tabell 3, ekvation (6)).



Figur 14. Residualdiagram för modell med kontinuerliga DTW-värden. Spridningen är mer homogen än för modell med klassificerade värden vilket indikerar bättre uppfyllda modellantaganden.



Figur 15. Q-Q plot för modell med kontinuerliga DTW-värden. Residualerna följer normalitetslinjen relativt bra med viss avvikelse i svansarna.

4.2.2 Utökade modeller med fler variabler

Den utökade modellen behöll interaktionstermen mellan kontinuerlig DTW (*DTWI*) och *jordart* (*JAm*) samt inkluderade ytterligare tre variabler: *virkesförråd* (*VF*), *jorddjup* (*JD*) och *lutning* (*L70*). *Höjd över havet* (*H*) och *torvdjup* (*TD*) exkluderades på grund av problem som diskuterats i metodavsnittet. Den utökade modellen förklarade ungefär 24% av variationen i responsvariabeln, vilket var ytterligare en förbättring jämfört med basmodellen (justerat $R^2=0.178$). *DTWI* förblev statistiskt signifikant, interaktionstermen var inte heller i denna modell signifikant. *Virkesförråd* visade ett svagt negativt samband men var inte statistiskt signifikant. Varken *jorddjup* eller *lutning* påverkade responsvariabeln signifikant i denna modell heller. Modellekvation med ingående variabler och regressionskoefficienter ses i appendix bilaga C (tabell 3, ekvation (7)).

En modifierad utökad modell utan interaktionsterm men med både *DTWI* och *JAm* inkluderade som huvudeffekter visade liknande förklaringskraft ($R^2=0.233$). Däremot ökade justerat R^2 något till 0.188 vilket tyder på att exkluderingen av interaktionstermen ledde till en modell som är något bättre på att förklara variationen i responsvariabeln. Modellekvation med ingående variabler och regressionskoefficienter ses i appendix bilaga C (tabell 3, ekvation (8)).

När *DTWI* byttes mot *TD* i den utökade modellen förbättrades modellens förklaringskraft ytterligare något ($R^2=0.245$, justerat $R^2=0.2$). *Torvdjup* var statistiskt signifikant i modellen med en negativ koefficient. Återigen visade de andra variablerna ingen signifikant effekt.

Effekt av enskilda och kombinerade förklarande variabler genom regression av alla delmängder

Tabell 1 summerar resultaten från regressionen av alla delmängder utgående från basmodellen (modellnummer med index Ab). Basmodellen som tidigare visats fick ett R^2 -värde på 0.194 med justerat $R^2=0.155$ och $AIC=92.87$. Efterföljande modeller byggdes genom att stegvis lägga till upp till tre ytterligare variabler till modellen. De två bästa modellerna för varje storlek av modell valdes

baserat på R^2 . Resultaten visar att modellens prestanda generellt förbättras med fler variabler även om förbättringen minskar för varje ytterligare term.

När *virkesförråd* (*VF*) lades till basmodellen förbättrades R^2 till 0.223 och justerat R^2 till 0.177 med en minskning av AIC. Tillägg av *jorddjup* (*JD*) istället gav en liknande förbättring (modell 2_{Ab}). När både *VF* och *SL70* lades till (modell 3_{Ab}) ökade förklaringsgraden ytterligare med den lägsta AIC av alla modeller, vilket indikerar den bästa modellanpassningen. Att inkludera *JD* istället för *SL70* resulterade i något lägre prestanda medan att lägga till alla tre variabler (modell 5_U) inte väsentligt förbättrade R^2 eller justerat R^2 och resulterade i högre AIC. Sammantaget gav modellen med $DTW1 \times JA$, *VF* och *L70* den bästa avvägningen mellan komplexitet och förklaringskraft.

I Tabell 1 sammanfattas även resultaten från regressionen av alla delmängder utgående från en tom modell, utan interaktionseffekter (modellnummer med index A). Samtliga möjliga kombinationer av de förklarande variablerna (*DTW1*, *JAm*, *VF*, *JD* och *L70*) testades i en automatiserad process. För varje antal inkluderade variabler sparades de två modeller som presterade bäst utifrån justerat R^2 , R^2 och AIC i tabellen (alla möjliga kombinationer presenteras inte här). Det möjliggjorde identifiering av de bäst passande modellerna där interaktionseffekten inte inkluderades. Den enklaste modellen (modell 6_A), som enbart inkluderade *DTW1*, förklarade 15.4 % av variationen i responsvariabeln och hade ett relativt lågt AIC-värde. Modellen med enbart *lutning* (modell 7_A) presterade däremot betydligt sämre. När fler variabler inkluderades förbättrades modellens förklaringskraft. Modell 8 med *DTW1* och *VF* hade ett R^2 på 0.195 och näst lägst AIC. Den bästa modellen (modell 11_A) erhöll ett justerat R^2 på 0.191. Den sista modellen (modell 14_A) med alla fem förklarande variabler gav en marginell förbättring i förklaringskraft men med lägre justerat R^2 men högre AIC, vilket tyder på att den enklare modellen presterade bättre.

Resultaten från regressionen med alla delmängder från tom modell där alla möjliga interaktioner och variabler sågs som potentiella förklarande variabler summeras i tabell 1 (modellnummer med index Ai). Modell 15_{Ai} och 16_{Ai} som endast innehöll en interaktionsterm ($DTW1 \times L70$) respektive $DTW1 \times VF$) visade på en förklaringskraft runt 0.20 med justerat R^2 mellan 0.17 och 0.18. När interaktionstermer kombinerades förbättrades anpassningen. Till exempel uppnådde modell 17_{Ai} ett R^2 -värde på 0.28 och justerat R^2 över 0.22 med lägst AIC-värde. Modell 19_{Ai} presterade bäst med justerat R^2 men med högre AIC. Modell 21_{Ai} erhöll det högsta R^2 -värdet men en marginell förbättring av justerat R^2 och ett sämre AIC-värde vilket innebär att modell 17_{Ai} var bättre balanserad.

Effekt av alternativa datakällor (SLU:s markfuktighetskarta och fältbestämd jordart)

För att utvärdera hur skillnaderna mellan datakällorna påverkade resultaten i modellen testades tre regressionsmodeller där markfukt (*MF*) från SLU:s markfuktighetskarta och jordart från fältbestämning (*JAf*) användes istället för *DTW1* och kartbaserad jordart (*JAm*) i basmodellen, sammanfattning av resultaten ses i tabell 1. I första modellen byttes *DTW1* ut mot *markfukt* (*MF*) men *kartbestämd jordart* (*JAm*) behölls. Modellekvation med ingående variabler och regressionskoefficienter ses i appendix bilaga C (tabell 3, ekvation (9)). Modellen förklarade 22.9% av variationen i responsvariabeln med ett justerat R^2 på 0.191. *MF* hade en signifikant negativ effekt på log(CBR) ($\beta = -0.0125$, $p < 0.001$). Interaktionen mellan *MF* och ler-silt var signifikant positiv medan interaktionen med morän inte var statistisk signifikant.

I den andra modellen ersattes kartbaserad jordart med *fältbestämd jordart* med *DTW1* som fuktighetsindex. Denna modell presterade något bättre med $R^2 = 0.258$ och justerat R^2 på 0.222. *DTW1* hade en positiv effekt ($\beta = 0.0934$, $p < 0.001$) med *JAf*-variabeln för morän också signifikant positiv. Modellekvation med ingående variabler och regressionskoefficienter ses i appendix bilaga C (tabell 3, ekvation (10))

Den sista modellen inkluderade både *MF* och *JAf* och var den som presterade med det högsta R^2 - och justerade R^2 -värdet (0.291 respektive 0.257). *MF* var även i denna modell signifikant samt båda interaktionstermerna också. Modellekvation med ingående variabler och regressionskoefficienter ses i appendix bilaga C (tabell 3, ekvation (11))

Tabell 1. Sammanställning av regressionsmodeller med olika kombinationer av förklarande variabler. Resultaten redovisar modellnummer, inkluderande variabler, R^2 , justerat R^2 samt AIC-värde för att jämföra modellernas prestanda med och utan interaktionstermer (interaktion mellan två variabler visas med $\times$). Modellnummer med index B, klass och B, kont står för basmodell med klassificerade respektive kontinuerliga värden. Modellnummer med index Ab, A, Ai står för bästa delmängdsregression från basmodellen, från tom modell utan interaktioner respektive tom modell med interaktioner. Index U står för utökad modell. Det bästa justerat R^2 -värdet, R^2 samt AIC-värdet är markerat med ljusgrått för både modeller från regression av alla delmängder samt med alternativa datakällor. Den bäst presterande modellen är markerad i mörkgrått.

Modell	Variabler	R^2	adj R^2	AIC
0_{B,klass}	<i>DTW</i> $\times$ <i>JAm</i>	0.10	0.06	104.4
0_{B,kont}	<i>DTW1</i> $\times$ <i>JAm</i>	0.19	0.16	92.87
1_{Ab}	<i>Bas</i> + <i>VF</i>	0.22	0.18	90.89
2_{Ab}	<i>Bas</i> + <i>JD</i>	0.21	0.17	92.41
3_{Ab}	<i>Bas</i> + <i>VF</i> + <i>L70</i>	0.23	0.18	91.30
4_{Ab}	<i>Bas</i> + <i>VF</i> + <i>JD</i>	0.23	0.18	91.43
5_U	<i>Bas</i> + <i>VF</i> + <i>JD</i> + <i>L70</i>	0.24	0.18	92.59
6_A	<i>DTW1</i>	0.15	0.15	90.20
7_A	<i>L70</i>	0.11	0.10	96.31
8_A	<i>DTW1</i> + <i>VF</i>	0.20	0.18	86.78
9_A	<i>DTW1</i> + <i>JAm</i>	0.19	0.17	89.52
10_A	<i>DTW1</i> + <i>JAm</i> + <i>VF</i>	0.22	0.19	87.65
11_A	<i>DTW1</i> + <i>VF</i> + <i>L70</i>	0.21	0.19	86.52
12_A	<i>DTW1</i> + <i>JAm</i> + <i>VF</i> + <i>L70</i>	0.23	0.19	88.17
13_A	<i>DTW1</i> + <i>JAm</i> + <i>VF</i> + <i>JD</i>	0.23	0.19	88.32

14_A	$DTW1 + JAm + VF + JD + L70$	0.23	0.19	89.51
15_{Ai}	$DTW1 \times L70$	0.20	0.18	88.27
16_{Ai}	$DTW1 \times VF$	0.20	0.17	88.74
17_{Ai}	$DTW1 \times L70 + JAm \times VF$	0.28	0.22	86.56
18_{Ai}	$DTW1 \times L70 + JAm \times JD$	0.27	0.21	88.43
19_{Ai}	$DTW1 \times JAm + JAm \times L70 + JAm \times VF$	0.30	0.21	90.31
20_{Ai}	$DTW1 \times L70 + JAm \times L70 + JAm \times VF$	0.30	0.22	89.19
21_{Ai}	$DTW1 \times VF + JAm \times L70 + JAm \times JD + JD \times VF$	0.31	0.23	89.61
22_{Ai}	$DTW1 \times VF + JAm \times L70 + JAm \times JD + JAm \times VF$	0.31	0.22	91.90
23	$MF \times JAm$	0.23	0.19	88.11
24	$DTW1 \times JAf$	0.26	0.22	83.83
25	$MF \times JAf$	0.29	0.26	78.86

5 Diskussion

5.1 Tolkning av sambanden mellan markens bärförmåga och geodata

5.1.1 Effekten av valt tröskelvärde för flödesackumulering på sambandet mellan DTW och bärförmåga

En central del studien var att undersöka hur olika tröskelvärden för flödesackumulering (FIA) påverkar relationen mellan DTW och markens bärförmåga (mätt som CBR). Resultaten visade att ett tröskelvärde på 1 hektar gav den starkaste korrelationen med CBR på cirka 0.37. Detta tyder på att en finare representation av flödesnätverk (lägre tröskelvärden) bättre fångar markfuktighet, en kritisk faktor för bärförmåga. Att 1 hektar hade starkast korrelation överensstämmer med tidigare studier, exempelvis Ågren m.fl. (2014), där tröskelvärden mellan 0.5 och 1 hektar visat sig vara särskilt effektiva för att modellera markfuktighet i fuktiga miljöer. Vidare stödjer Schönauer m.fl. (2022) användningen av låga tröskelvärden i kombination med högupplösta data. De konstaterade att noggrannheten i DTW-beräkningar förbättras vid upplösningar under 5-10 meter, vilket överensstämmer med användningen av 1 meters DEM i denna studie. De beskriver också att tillgång till så högupplöst data, som ofta finns i Sverige, möjliggör nationella DTW-kartor där tröskelvärden vanligtvis sätts mellan 0.5 och 2 hektar i syfte att bättre fånga småskalig topografisk variation. Särskilt för känsliga marktyper där horisontell vattenrörelse är vanligt förekommande, kan låga tröskelvärden vara avgörande för att identifiera vattenmättade områden där bärförmågan är låg. Detta motiverade att fortsätta använda 1 hektars tröskelvärde även i denna studie. Det bör dock noteras att fältmätningarna genomfördes under en ovanligt torr period (juni 2022), med cirka 20% lägre nederbörd än normalt för perioden. Det innebär att grundvattennivåerna sannolikt var lägre än vanligt, vilket kan ha påverkat sambandet mellan DTW och faktiskt markfukt. Under torra förhållanden tenderar yt- och grundvatten att samlas i de lägsta, naturliga dräneringspunkterna i landskapet, snarare än att fördelas över ett stort område. Det innebär att ett högre tröskelvärde, exempelvis 3 hektar, kunde ha varit motiverat för att bättre fånga större ackumuleringsområden som förblir fuktiga även vid torka. Valet av FIA bör därför inte betraktas som statistiskt, utan snarare som beroende av rådande hydrologiska förhållanden. Det vore därför intressant att i framtida forskning undersöka om det finns ett mer generellt angreppssätt för val av tröskelvärde, beroende på exempelvis årstid eller klimat.

5.1.2 Hur lutningens upplösning påverkar tolkningen av topografins betydelse

För att undersöka alternativa geospatiala variabler för att skatta markens bärförmåga analyserades bland annat lutningens upplösning och dess samband med CBR. Resultaten visade att en upplösning på 70 meter gav det starkaste sambandet, medan både finare (20-40 meter) och grövre (100 meter) upplösningar gav svagare korrelationer. Detta kan tolkas som att topografins inverkan på bärförmåga är mest relevant på en medelfin skala som är tillräckligt detaljerad för att fånga lokala variationer men samtidigt inte så fin att brus uppstår. Att korrelationerna i intervallet 20-80 meters upplösning varierade mellan 0.23 och 0.29 antyder att detta intervall kan vara optimalt, men att 70 meters upplösning ger en bra balans för att fånga topografiska fuktvariationer.

Att lutningens prediktiva förmåga avtog vid grövre upplösningar tyder på att relevant information går förlorad när topografin förenklas. Samtidigt kan en för fin upplösning leda till att lutningsberäkningen i hög grad påverkas av punktvisa detaljer, exempelvis enskilda block, snarare än topografiska trender över större områden som påverkar vattenflödet. Detta stöds av Grohmann

(2015) som i sin studie från tre områden i Sydamerika konstaterade att det inte är optimalt att använda lågupplösta höjddata för analyser på regional nivå för att viktiga parametrar som lutning påverkas kraftigt av lägre upplösning. Lutningen påverkas genom att maxvärden, medelvärden och standardavvikelse minskar. I studien konstaterades även att om det inte finns begränsningar i data bör man beräkna lutning från data med hög upplösning och sedan, om det är nödvändigt, resampla till grövre upplösning. Detta tyder på att upplösning är en viktig sak att beakta vid GIS-modellering där val av rätt skala kan vara avgörande för tolkning och prediktion.

5.1.3 Tolkning av samband mellan geovariabler och markens bärförmåga

De parvisa sambanden mellan geovariabler och CBR visade flera intressanta och delvis oväntade mönster. Som förväntat hade DTW ett positivt samband med CBR där högre DTW-värden (torrare förhållanden) kopplades till högre bärförmåga. Markfukt och torvdjup visade tydliga negativa samband med CBR, vilket förväntades utifrån teorin att våt och organisk jord har lägre bärförmåga som bekräftats i tidigare studier, bland annat av Uusitalo och Ala-Ilomäki (2015). Sambandet mellan höjd över havet och CBR var däremot mycket svagt vilket tyder på att höjd inte direkt påverkar bärförmågan. Även detta var ett förväntat resultat eftersom det snarare är relativ höjd och lutning som styr vattenflöden och därmed markfuktigheten. Det kan också bero på de begränsade höjdvariationerna som finns i studieområdet (cirka 25-50 meter över havet). På större skala, där topografin är mer varierad än i denna studie, kan dock höjd korrelera med långsiktiga skillnader i medeltemperatur och nederbörd, vilket indirekt kan påverka markförhållanden och bärförmåga. Ett mer oväntat resultat var det negativa sambandet mellan virkesförråd och CBR-värden. Detta står i kontrast till antagandet att stora rotsystem i områden med högt virkesförråd bör stabilisera marken och öka bärförmågan. En möjlig förklaring kan vara att höga virkesförråd ofta förekommer i produktiva, fuktiga skogsbestånd där täta och stora trädkronor minskar markavdunstningen genom skuggning. Detta stämmer överens med resonemanget av Zhao m.fl. (2023) som noterade att större bestånd minskar solljusexponeringen på marken vilket minskar avdunstning och därigenom ökar markfukten. Tät skog kan dock också medföra ökad interception, att nederbörd fångas upp av trädkronor, vilket minskar vattenmängden som når marken. Högre evapotranspiration från tätare skogsbestånd innebär också lägre grundvattennivå, vilket i sin tur förväntas öka markens bärförmåga. Dessa motverkande processer gör sambandet mellan virkesförråd och markfukt komplext. Det är även möjligt att virkesförrådet som enskilt mått inte fullt ut fångar trädens effekt på markstabiliteten, där faktorer som exempelvis trädslag, beståndsålder eller rotstruktur kan vara andra viktiga kompletterande variabler. I studien av Uusitalo och Ala-Ilomäki (2015) visades en stark korrelation mellan markens skjuvhållfasthet och massa av levande rötter. Studien fann däremot inget tydligt samband mellan beståndsvolym och den uppmätta skjuvhållfastheten. Detta stödjer att virkesförråd möjligtvis inte speglar rotmassans omfattning, vilket är särskilt relevant eftersom rotmassan påverkar markens bärförmåga. Chen m.fl. (2025) noterade skillnader i markfuktighet beroende på skogens ålder och beståndstäthet. När beståndstätheten ökade noterades att markfukten var högre i unga skogar än i äldre mer mogna skogar. Dessa resultat stödjer antagandet att kompletterande variabler kan vara nödvändiga. Ytterligare faktorer som kan ha påverkat sambandet mellan virkesförråd och CBR är att virkesförråd har för lågupplöst data och att det är låg variation av skogsvolym mellan provpunkterna.

Ytterligare ett viktigt resultat var förekomsten av en outlier i CBR-värdena, med en observation som hade ett mycket högt värde omkring 50. Detta speglar och kan bero på att det är stora lokala variationer i markegenskaper, till exempel kan marken vara olika kompakterad eller ha olika

förekomst av sten i moränmarker. Det är viktigt att beakta sådana outliers eftersom de kan påverka regressionsmodellens resultat.

5.2 Prediktion av markens bärförmåga med geodata

5.2.1 Fördelar med kontinuerliga DTW-värden för prediktion av bärförmåga

Jämförelsen mellan modeller som använde klassificerade DTW-värden (våt/torr) och kontinuerliga DTW-värden visade att kontinuerliga värden signifikant förbättrade modellens förklaringskraft (R^2 ökade från 0.1 till 0.19, en 90 % förbättring). Detta understryker vikten att mer detaljerad information om markfuktens variation är värdefull för prediktionen av bärförmåga. Den kontinuerliga modellen fångar gradvisa förändringar i fukt bättre än den klassificerade modellen, där förenklade övergångar riskerar att missa viktiga variationer vilket är logiskt eftersom fuktvariationer inte förändras abrupt utan övergår gradvis. Resultatet stärker därför att mer detaljerade geodata förbättrar den prediktiva modelleringen och bör eftersträvas i vidare studier. Vid jämförelse av modellernas residualer framkom ytterligare stöd för den kontinuerliga modellen. Den klassificerade modellens residualer visade tydliga vertikala mönster vilket indikerar att modellen inte lyckas skilja på variationen inom de två kategorierna. Det innebär en förenkling av verkligheten där fuktförhållandena skulle kunna skilja sig mycket även inom samma klass. Den kontinuerliga modellens residualer var däremot mer utspridda och homogena vilket tyder på att modellen bättre fångade den underliggande variationen. Det bör dock noteras att även den kontinuerliga modellen har begränsningar. Även om prestandan förbättrades var förklaringsgraden fortfarande relativt låg, vilket indikerar att DTW, även som kontinuerlig variabel, inte är den enda faktorn som påverkar bärförmågan. Det kan bland annat bero på att DTW-indexet inte är en direkt mätning av markfukt och kortsiktiga och lokala variationer inte nödvändigtvis fångas. Dessutom påverkar andra faktorer som jordarternas struktur, kompakteringsgrad och innehållet av organiskt material markens bärförmåga. Trots detta visar resultaten tydligt att användning av kontinuerliga variabler för representation av hydrologiska förhållanden är mer lämpligt än kategorisering i fasta klasser.

5.2.2 Hur kompletterande geodata påverkar modellens träffsäkerhet

Inkludering av variabler som lutning, virkesförråd och jorddjup i en utökad modell ökade visserligen förklaringskraften marginellt, men flera av variablerna var inte statistiskt signifikanta. Detta indikerar att DTW är den starkaste prediktorn i modellen, medan övriga variabler bidrar med svagare prediktiv kraft. Interaktionen mellan variabler och markens fysiska egenskaper kan vara komplex och påverkas av lokala förhållanden vilket kan vara svårt att fånga med en relativt liten datamängd ($n=108$). Den negativa korrelationen mellan virkesförråd och CBR pekar på indirekta effekter via markfuktighet och vegetationstäthet snarare än direkta mekaniska effekter, vilka skulle vara intressant att utforska vidare. Resultatet pekar även på begränsad datakvalitet och upplösning som bör arbetas vidare med och utvecklas för mer tillförlitliga resultat. Att jorddjup inte visade signifikanta samband trots en teoretisk koppling till bärförmåga, där djupare jord borde vara stabilare, kan bero på att jorddjupet varierar inom korta avstånd eller är beroende av andra faktorer som jordart. När DTW byttes ut mot torvdjup förbättrades modellen ytterligare ($R^2=0.245$) vilket indikerar på torvdjupets direkta mekaniska påverkan på bärförmåga (till exempel dess höga kompressibilitet). Torvdjupets höga korrelation med *DTWI* (-0.81) försvårar dock att använda dessa tillsammans och samtidigt urskilja deras individuella effekt.

5.2.3 Interaktionen mellan jordart och fuktighet i förklaringen av bärförmåga

I teorin förväntas vissa jordarter som lera och torv påverkas mer av fukt än till exempel sandjordar. Till exempel noterade Uusitalo m.fl. (2019) att ler- och siltjordar var mycket svaga vid hög markfukt och varierar mycket i bärförmåga beroende på markfukt. De visade däremot att sandjordar har en mer stabil variation i bärförmåga oavsett vatteninnehåll. Modellen i denna studie visade att interaktionstermerna mellan DTW och kartbaserad jordart inte var statistiskt signifikanta. En möjlig förklaring till det är att jordartskartan inte fångar den verkliga variationen i markens textur och struktur på plats. Dock visade uppdelningen av data i jordartsspecifika modeller att sambandet varierar. Vid separata analyser för varje jordart för sig visade modellen för sandjordar ett signifikant och positivt samband mellan DTW och $\log(\text{CBR})$ vilket indikerar att DTW är en relevant prediktor för bärförmåga i sådana marktyper. Däremot var sambandet för ler-silt- och moränjordar svagt och inte signifikant vilket tyder på att sambandet mellan hydrologiska förhållanden och bärförmåga istället beror på jordens struktur och dräneringsegenskaper. För grovkorniga sandjordar kan DTW användas som en indikator på bärförmåga, troligen på grund av det direkta sambandet mellan topografisk dränering och markfuktighet. Sandens höga genomsläpplighet och låga kapillära vattenhållning gör att förändringar i grundvattennivå snabbt påverkar den faktiska fukthalten i det bärande lagret vilket resulterar i en tydligare korrelation med bärförmåga. Detta kan förklara varför modeller som enbart fokuserar på sandiga jordar visade bättre prestanda jämfört med den fullständiga modellen som inkluderade alla jordarter. Finkorniga jordar behåller fukt även under förhållanden med djupare grundvattennivåer (höga DTW-värden), vilket tyder på att topografiskt härlett fuktindex som DTW kanske inte fullt ut representerar det hydrologiska förhållandena. Resultat från tidigare studier, såsom Celik m.fl. (2022), stärker antagandet att jordart har en avgörande betydelse för markfuktighetsmodelleringens noggrannhet på grund av vattenhållande egenskaper. I deras studie observerades att jordar med hög andel sand uppvisade mer stabila markfuktighetsvärden, vilket gjorde dem enklare att modellera jämfört med jordar med högre halt av lera eller silt. Den begränsade vattenhållande förmågan och mindre fuktvariationer över tid bidrog till en förbättrad modellnoggrannhet. I kontrast visade ler- och siltjordar högre vattenhållning och långsammare fuktförlust, vilket ledde till större variation i markfukt över tid som försvårade modelleringen. Även om DTW kan vara en viktig indikator i vissa jordar, minskar dess prediktiva kraft i ler-siltjordarna där ytterligare variabler som exempelvis direktmätt fukt kan vara nödvändiga för att få ett mer tillförlitligt resultat. Att antalet observationer var relativt jämnt fördelat mellan jordarterna stärker tolkningen att det är jordarternas fysikaliska egenskaper snarare än urvalsstorleken som skillnaderna i modellens prestanda beror på. Det är också viktigt att beakta att DTW inte mäter aktuell markfukt vid provtagningstillfället utan utgör ett topografiskt härlett index baserat på höjdmodellen och markvattenflöde. Som statistiskt mått kan det därför missa tillfälliga eller lokala variationer. Det skulle också kunna förklara varför sambandet mellan DTW och bärförmåga är svagare i lerrika jordar, där kanske ytavrinning, markpackning eller vegetation har större påverkan på fuktvariationer.

Datasetets grova uppdelning mellan fina och grova jordar med begränsad överlappning kan även ha bidragit till att interaktionstermerna inte blev signifikanta i den gemensamma modellen. Om sandjordar framförallt förekommer i områden med djupare grundvatten (høgt DTW) och lerrika jordar i områden med grundare grundvatten (lågt DTW) blir det svårt för modellen att separera effekterna av DTW och jordart. Det kan leda till en medelvärdeseffekt där olika jordarters motsatta effekter på DTW tar ut varandra i modellen och de markspecifika trenderna döljs i den gemensamma modellen, trots att de separata analyserna visar tydliga skillnader. Detta bidrar till konsekvenserna för framtida modellutveckling där resultaten tyder på att det inte är optimalt att

använda en och samma modell för att skatta markens bärförmåga i alla jordarter. Jordartsspecifika modeller presterade generellt bättre och kan därför vara att föredra vid praktiska tillämpningar. Sammanfattningsvis återspeglar den icke signifikanta interaktionen mellan DTW och jordart sannolikt grundläggande skillnader i hur grova och fina jordar reagerar på hydrologiska förhållanden. Medan DTW fungerar som en prediktor för sandjordar, är användningen mer begränsad i ler- och siltdominerade marker, där andra variabler kan spela större roll för att bestämma bärförmågan.

När fältbestämd jordart användes i modellen förbättrades däremot prediktionen, vilket tyder på att lokal variation har en betydelse. Eftersom GIS-prediktioner bygger på jordartskartan väcker det frågan om kartunderlaget är tillräckligt för denna typ av prediktiva modeller som studien bygger på. Möjligen krävs en mer omfattande uppdatering av dessa kartor eller en kombination med fältdata eller maskininlärning för att förbättra tillförlitligheten ytterligare.

5.3 Studiens begränsningar och förslag till framtida forskning

Resultaten visar att det finns stor potential i att använda GIS-baserade modeller för att uppskatta markens bärförmåga, särskilt genom användning av kontinuerliga DTW-värden som index för markfukt. Samtidigt tydliggör studien ett antal begränsningar, både metodologiska och datatekniska som bör beaktas vid tolkning och vidareutveckling av modellerna. En första begränsning gäller tillgången till fältdata. Av de ursprungliga 120 provpunkterna kunde endast 108 användas vilket minskar det statistiska underlaget ännu mer från det från början redan begränsade antalet provpunkter. Detta påverkar möjligheterna att modellera komplexa samband, särskilt när många variabler inkluderas. Ett mindre dataset ökar risken för överanpassning och begränsar möjligheten till uppdelning av tränings- och testdata för validering. I heterogena miljöer som skogsmark, där markförhållanden kan variera mycket på små avstånd, blir det särskilt problematiskt. En större och mer geografiskt utspridd mätvärdesuppsättning skulle möjliggöra både mer tillförlitliga prediktioner och utvärderingar av modeller.

En annan central begränsning är kvaliteten på de geodata som modellerna bygger på. Jordartskartan visade sig i flera fall inte spegla de faktiska förhållandena i fält vilket skapar osäkerheter i analyser som är beroende av jordartsspecifika effekter. Ett exempel på detta är en provpunkt där det uppmätta CBR-värdet avvek kraftigt från övriga och där fältobservationer och kartlagda jordart inte stämde överens. Det illustrerar risken med att förlita sig enbart på statiska, karterade data i småskaliga studier. För att förbättra träffsäkerheten bör framtida studier antingen fokusera på att förbättra befintliga kartor, till exempel genom fältkalibrering, eller utveckla modeller som är mindre beroende av denna typ av underlag. Jordartsspecifika skillnader i modellerna tyder också på att en gemensam modell för alla jordar inte fullt ut fångar komplexiteten i markens styrka. Framtida studier bör fokusera på jordartsspecifika modeller eller använda icke-linjära metoder såsom maskininlärning för att bättre fånga interaktionseffekter och lokala variationer. Geodatans upplösning och statiska karaktär utgör också en källa till fel. Exempelvis kan interpolerade jorddjupsmodeller och karterade jordarter missa lokal variation. Eftersom markens egenskaper förändras över tid, exempelvis beroende på säsong, väder och vegetation, innebär användningen av statiska kartlager att vissa viktiga aspekter missas i modellen. Det kan i sin tur minska modellens förmåga att prediktera verkliga förhållanden.

Ett särskilt fokus i denna studie har varit användningen av DTW som indikator för markfuktighet. Även om detta index visade sig vara användbart, påverkas dess precision kraftigt av de parametrar

och algoritmer som används vid beräkningen. Val av flödesalgoritm (exempelvis D8 eller D_{∞}), tröskelvärde (FIA), samt upplösningen på den digitala höjdmodellen har alla direkt inverkan på hur väl DTW speglar faktiska vattenflöden. D8-algoritmen, som styr vattenflödet till en av åtta närliggande celler, är enkel och snabb, men kan leda till överdrivet koncentrerade flöden. Alternativt kan D_{∞} -algoritmen ge mer realistiska flödesmönster genom att möjliggöra kontinuerliga riktningar. Valet mellan dessa påverkar hur vattenflödet fördelas över landskapet och därmed hur DTW-beräkningen utfaller (Qin m.fl., 2007). En annan viktig parameter är tröskelvärdet för flödesinitiering (FIA), som avgör hur stort avrinningsområde som krävs för att en cell ska betraktas som början på ett vattenflöde. Låga FIA-värden leder till ett tätare nätverk av små flödeskanaler, vilket kan vara användbart för att identifiera lokala fuktvariationer. Höga värden kan istället ge ett mer generaliserat nätverk som fokuserar på större avrinningslinjer, vilket kan vara relevant i grovskaliga analyser. Valet av FIA-värde bör anpassas efter syftet med modellen och den rumsliga skalan på analysen (Ågren, Lidberg och Ring, 2015). Högupplöst data möjliggör detaljerade analyser men kan också öka känsligheten för små irrelevanta variationer i topografien och leda till fel i modellen samt vara mer beräkningskrävande. Dessa metodval bör därför göras med hänsyn till både analysens skala och syfte. Som Deng och Bauer (2007) konstaterat fungerar miljömodeller olika beroende på vilken skala de körs på. De menar också att det inte är säkert att man kan använda samma upplösning för alla indata och olika variabler (som lutning och markfuktighet) reagerar olika starkt på olika skalförändringar. Ett annat förenklingsmoment i denna studie är antagandet om linjära samband i regressionsmodellerna. I verkligheten är relationen mellan exempelvis markfukt, vegetation eller jordart ofta icke-linjär och interaktiv. Vegetation kan till exempel påverka både fuktförhållanden och markstruktur samtidigt som jordarten styr hur vatten lagras eller rinner av. För att bättre fånga dessa komplexa samband rekommenderas framtida forskning att tillämpa mer avancerade, icke linjära modeller, exempelvis maskininlärningsmetoder som Random forest eller Gradient Boosting. Dessa modeller kan hantera interaktioner och icke-linjäritet utan att förutsätta ett specifikt samband, men det kräver större datamängder för att undvika överanpassning.

Ytterligare en begränsning i denna studie är att mätningarna begränsades geografiskt till områden runt Uppsala, inklusive urbana områden som Stadsskogen. Ett urbant skogsområde kan ha specifik markanvändning, vegetationstyper eller dräneringsförhållanden som avviker från andra skogsmarker. Exempelvis kan dagvattenledningar och hårdgjorda ytor förändra naturliga vattenflöden, vilket i sin tur påverkar markfukt och därmed bärförmåga. Urban skogsmiljö som ligger nära vägar och byggnader kan ha påverkade vattenflöden där regnvatten leds till eller från skogen via system som påverkar den naturliga infiltrationen och avrinningen jämfört med mer opåverkade områden. Framtida studier bör inkludera fler platser i olika landskapstyper för att öka den geografiska spridningen och generaliserbarheten i modellerna. Det vore även värdefullt att genomföra mätningar under olika klimat- eller hydrologiska förhållanden, till exempel under våtare perioder för att utvärdera hur robusta modellerna är över tid. Även om de befintliga modellerna ger goda indikationer för skogsbrukets behov av planering och förebyggande av skador kan vidare forskning säkerställa att de är tillräckligt bra för en bred användning i olika miljöer.

Urvalet av förklarande variabler baserades i första hand på praktisk avgränsning av studiens omfattning samt tillgången på geodata. De valda variablerna, främst DTW, lutning och jordart, valdes utifrån deras teoretiska och väl dokumenterade samband med markfuktighet, dränering och markens fysiska bärförmåga. Dessa faktorer har i tidigare forskning visat sig påverka maskinframkomlighet i skogsbruket, vilket gjorde dem till rimliga utgångspunkter. Samtidigt

innebar denna avgränsning att andra potentiellt relevanta variabler inte inkluderades. Bland de terrängindikatorer som skulle kunna fördjupa analysen finns plan- och profilkurvatur (plan och profile curvature), relativ höjd, topografiskt våtindex (TWI) och exponering (aspect). Dessa variabler fångar olika aspekter av terrängens form och vattenfördelning, vilket i sin tur kan ha betydelse för markfukt och därmed bärförmåga. Till exempel kan kurvatur ge information om markytans konkava eller konvexa egenskaper vilket påverkar var vatten tenderar att samlas eller rinna av. Utöver terrängindikatorer finns det även andra typer av förklarande variabler som skulle vara intressanta att undersöka i framtida studier. Vegetationstäckning, exempelvis i form av trädhöjd, biomassamängd eller skogstyp kan påverka både infiltration, evapotranspiration och markstruktur vilket i sin tur påverkar markens fuktbalans och hållfasthet. Markanvändning och historik såsom tidigare skogsbruksåtgärder, körskador eller dikning kan också ha betydande inverkan på markens egenskaper. Andra potentiellt relevanta variabler inkluderar marktemperatur och nederbördsmonster eller data från markradar för att bättre uppskatta jorddjup och markstruktur.

Urvalet grundades alltså i huvudsak på vad som var praktiskt genomförbart snarare än en fullständig kartläggning av alla möjliga prediktorer. Fokus låg på de variabler som baserat på tidigare studier och teoretisk förståelse antogs ha ett meningsfullt samband med markens bärförmåga. För framtida forskning vore det dock värdefullt att utvidga spektrumet av terrängindikatorer och inkludera fler hydrologiska data för att skapa en mer heltäckande modell av markens bärförmåga.

6 Slutsatser

Studien visade att GIS-baserad modellering kan vara ett hjälpsamt verktyg för att skatta markens bärförmåga i skogsmarker. DTW som indikator på markfukt visade sig vara den bästa enskilda variabeln för att förutsäga CBR. Kontinuerliga DTW-värden gav en betydligt högre förklaringskraft än klassificerade. Valet av tröskelvärde för DTW-beräkningar påverkar sambandet med bärförmågan. Ett tröskelvärde på 1 hektar visade starkast samband med CBR i denna studie. Alternativa geodata såsom lutning, jorddjup och virkesförråd bidrog i viss mån till en förbättrad förklaringskraft men deras individuella påverkan var begränsad. Det negativa sambandet mellan virkesförråd och CBR beror förmodligen främst på lågupplöst data och låg variation mellan mätpunkterna. Det kan också möjligen bero på att täta bestånd ökar markfukt snarare än ger ökad stabilitet från rotsystemen. Det kan också tyda på ett komplext samband mellan vegetation och bärförmåga som inte kan speglas med enkla modeller.

Sammanfattningsvis kombinerade de mest effektiva modellerna DTW, virkesförråd samt lutning vilket uppnådde den bästa balansen mellan förklaringskraft och komplexitet. Resultatet tyder på att geodata kan ge värdefulla insikter för skogsbrukets planering av avverkning och skogsbilvägar, samtidigt betonas att användningen fortfarande bör kompletteras med fältvalidering och att data bör vara av hög kvalitet. Framtida arbete bör därför fokusera på att förbättra dataintegrationen, utöka fältmätningar och utforska mer avancerade dynamiska modelleringstekniker för att ytterligare utjämna glappet mellan geodatabaserade skattningar och verkliga förhållanden.

Referenser

- Ampoorter, E., Van Nevel, L., De Vos, B., Hermy, M. och Verheyen, K. (2010). Assessing the effects of initial soil characteristics, machine mass and traffic intensity on forest soil compaction. *Forest Ecology and Management*, 260(10), s. 1664–1676, doi:10.1016/j.foreco.2010.08.002.
- Angelstam, Per (2022). *Hållbart nyttjande av skogen– visioner för de svenska skogslandskapen*. Umeå: SLU Skogsmästarskolan. Rapport Skog 2022:3 No. Sveriges Lantbruksuniversitet. <https://www.slu.se/globalassets/ew/org/andra-enh/s/forskning/rapportserie/rapport-skog-2022-4-angelstam-low.pdf> [Hämtad: 2025-03-16].
- Arbianto, Reki, Yuono, Teguh och Gunarso, G. (2021). Comparison of California Bearing Ratio (CBR) Value Based on Cone Penetration Test (CPT) and Dynamic Cone Penetrometer (DCP). *Journal of Advanced Civil and Environmental Engineering*, 4(2), s. 70–78, doi:10.30659/jacee.4.2.70-78.
- Björnheden, Rolf, Hansson, Linnéa, Nordfjell, Tomas och Jönsson, Petrus (2022). *Minska risken för markskador! Del 1: Markens bärighet, markskador och hur de uppstår*. Skogforsk. No. 2022–52.
- Burt, T. P. och Butcher, D. P. (1985). Topographic controls of soil moisture distributions. *Journal of Soil Science*, 36(3), s. 469–486, doi:10.1111/j.1365-2389.1985.tb00351.x.
- Cambi, Martina, Certini, Giacomo, Neri, Francesco och Marchi, Enrico (2015). The impact of heavy traffic on forest soils: A review. *Forest Ecology and Management*, 338, s. 124–138, doi:10.1016/j.foreco.2014.11.022.
- Celik, Mehmet Furkan, Isik, Mustafa Serkan, Yuzugullu, Onur, Fajraoui, Noura och Erten, Esra (2022). Soil Moisture Prediction from Remote Sensing Images Coupled with Climate, Soil Texture and Topography via Deep Learning. *Remote Sensing*, 14(21), s. 5584, doi:10.3390/rs14215584.
- Chen, Hao, Zhang, Zhaowei, Yang, Xiangyu, Ai, Xin, Wang, Yutao och Liu, Ping (2025). Effects of forest age and stand density on the growth, soil moisture content, and soil carbon content of *Populus simoni* plantations in the sandy area of western Liaoning, Northeast China. *Scientific Reports*, 15(1), s. 2499, doi:10.1038/s41598-025-86215-4.
- Cherlinka, Vasyli (2024). *Soil Moisture: How To Measure & Monitor Its Level*. <https://eos.com/blog/soil-moisture/> [Hämtad: 2025-05-07].
- Deng, Y., Wilson, J. P. och Bauer, B. O. (2007). DEM resolution dependencies of terrain attributes across a landscape. *International Journal of Geographical Information Science*, 21(2), s. 187–213, doi:10.1080/13658810600894364.
- Echiverri, Laureen och Macdonald, S. Ellen (2019). Utilizing a topographic moisture index to characterize understory vegetation patterns in the boreal forest. *Forest Ecology and Management*, 447, s. 35–52, doi:10.1016/j.foreco.2019.05.054.
- ESRI (u.å.). *Esri Sverige | Vad är GIS (geografiska informationssystem)*. ESRI. <https://www.esri.se/sv-se/what-is-gis/overview> [Hämtad: 2025-03-20].
- Fastrup, Elsa (2024). *Kvantifiering av förändrad grundvattennivå vid simulerad dikesrensning*. Examensarbete. Uppsala universitet, Uppsala. <https://uu.diva-portal.org/smash/get/diva2:1862877/FULLTEXT01.pdf>.
- Grohmann, Carlos H. (2015). Effects of spatial resolution on slope and aspect derivation for regional-scale analysis. *Computers & Geosciences*, 77, s. 111–117, doi:10.1016/j.cageo.2015.02.003.
- Habiboullah, Amina och Louly, Mohamed Abdellahi (2023). Soil Moisture Prediction Using NDVI and NSMI Satellite Data: ViT-Based Models and ConvLSTM-Based Model. *SN Computer Science*, 4(2), s. 140, doi:10.1007/s42979-022-01554-7.
- Helsel, Dennis R., Hirsch, Robert M., Ryberg, Karen R., Archfield, Stacey A. och Gilroy, Edward J. (2020). *Statistical methods in water resources: U.S. Geological Survey Techniques and Methods, book 4, chap. A3*. <https://doi.org/10.3133/tm4a3>.
- Heppelmann, J. B., Talbot, B., Antón Fernández, C. och Astrup, R. (2022). Depth-to-water maps as

- predictors of rut severity in fully mechanized harvesting operations. *International Journal of Forest Engineering*, 33(2), s. 108–118, doi:10.1080/14942119.2022.2044724.
- Hoffmann, Stephan, Schönauer, Marian, Heppelmann, Joachim, Asikainen, Antti, Cacot, Emmanuel, Eberhard, Benno, Hasenauer, Hubert, Ivanovs, Janis, Jaeger, Dirk, Lazdins, Andis, Mohtashami, Sima, Moskalik, Tadeusz, Nordfjell, Tomas, Stereńczak, Krzysztof, Talbot, Bruce, Uusitalo, Jori, Vuillermoz, Morgan och Astrup, Rasmus (2022). Trafficability Prediction Using Depth-to-Water Maps: the Status of Application in Northern and Central European Forestry. *Current Forestry Reports*, 8(1), s. 55–71, doi:10.1007/s40725-021-00153-8.
- Holmgren, Peter (2021). *Skogsbruk får marken att växa. Vår dolda inlagring av kol i skogen*. Skogsindustrierna.
https://www.skogsindustrierna.se/siteassets/bilder-och-dokument/rapporter/sa-far-skogsbruk-marken-att-vaxa/sa-far-skogsbruk-marken-att-vaxa_2111082.pdf [Hämtad: 2023-03-12].
- Horn, Rainer och Fleige, Heiner (2011). Soil Structure and Mechanical Strength. I: Gliński, Jan, Horabik, Józef, och Lipiec, Jerzy (red.) *Encyclopedia of Agrophysics*. Dordrecht: Springer Netherlands, s. 777–780. https://doi.org/10.1007/978-90-481-3585-1_155.
- Håkansson, Inge, Voorhees, Ward B. och Riley, Hugh (1988). Vehicle and wheel factors influencing soil compaction and crop response in different traffic regimes. *Soil and Tillage Research*, 11(3), s. 239–282, doi:10.1016/0167-1987(88)90003-7.
- IBM (2023). *Examples and uses of GIS*. IBM.
<https://www.ibm.com/think/topics/geographic-information-system-use-cases> [Hämtad: 2025-03-31].
- Jones, Jeff (2017). *California bearing ratio typical values - CBR Testing UK*. CBR Testing.
<https://www.cbrtesting.com/california-bearing-ratio-typical-values/> [Hämtad: 2025-05-18].
- Karjalainen, Ville, Malinen, Jukka och Tokola, Timo (2024). Predicting bearing capacity and trafficability classes of forest roads using road properties and surrounding terrain information. *Road Materials and Pavement Design*, s. 1–18, doi:10.1080/14680629.2024.2434945.
- Kim, Ikhyun, Seo, Jaewon, Woo, Heesung och Choi, Byoungkoo (2025). Assessing Rutting and Soil Compaction Caused by Wood Extraction Using Traditional and Remote Sensing Methods. *Forests*, 16(1), s. 86, doi:10.3390/f16010086.
- Lantmäteriet (2023). *Markhöjdmall Nedladdning, grid 1+*.
<https://www.geodata.se/geodataportalen/srv/swe/catalog.search;jsessionid=EADE3B1ECF2BEEB61C3440994CCF05D5#/metadata/c510e63f-0bf3-46c9-ab8b-3b37a898af85> [Hämtad: 2025-03-27].
- Larsson, Rolf (2007). *Jords egenskaper*. Linköping: Statens geotekniska institut (SGI). No. 5.
<https://www.sgi.se/globalassets/publikationer/info/pdf/sgi-i1.pdf> [Hämtad: 2025-05-07].
- Lindsay, John B. (2014). The Whitebox Geospatial Analysis Tools project and open-access GIS. *Proceedings of the GIS Research UK 22nd Annual Conference, The University of Glasgow*, doi:10.13140/RG.2.1.1010.8962.
- Lindsay, John B. (u.å.). *WhiteboxTools User Manual*. whiteboxgeo.
https://www.whiteboxgeo.com/manual/wbt_book/ [Hämtad: 2025-05-06].
- Mohtashami, Sima (2011). *Bättre planering av avverkningssvägar med GIS*. Skogforsk. No. 2011–9.
https://www.skogforsk.se/contentassets/b2d5416aef45423fb97a8653d1a82e23/resultat_nr6_2011_low.pdf.
- Mohtashami, Sima (2022). GIS-based decision support systems to minimise soil impacts in logging operations. *Acta Universitatis Agriculturae Sueciae*, (2022:67), doi:10.54612/a.qq3cqbknd.
- Mohtashami, Sima, Eliasson, Lars, Hansson, Linnea, Willén, Erik, Thierfelder, Tomas och Nordfjell, Tomas (2022). Evaluating the effect of DEM resolution on performance of cartographic depth-to-water maps, for planning logging operations. *International Journal of Applied Earth Observation and Geoinformation*, 108, s. 102728, doi:10.1016/j.jag.2022.102728.

- Mohtashami, Sima, Eliasson, Lars, Jansson, Gunnar och Sonesson, Johan (2017). Influence of soil type, cartographic depth-to-water, road reinforcement and traffic intensity on rut formation in logging operations: a survey study in Sweden. *Silva Fennica, The Finnish Society of Forest Science*, 51(5), doi:<https://doi.org/10.14214/sf.2018>.
- Mohtashami, Sima, Hansson, Linnea och Eliasson, Lars (2023). Estimating Soil Strength Using GIS-Based Maps - A case study in Sweden. *European Journal of Forest Engineering*, 9(2), s. 70–79, doi:10.33904/ejfe.1321075.
- Murphy, P. N. C., Ogilvie, J. och Arp, P. (2009). Topographic modelling of soil moisture conditions: a comparison and verification of two models. *European Journal of Soil Science*, 60(1), s. 94–109, doi:10.1111/j.1365-2389.2008.01094.x.
- Murphy, Paul N. C., Ogilvie, Jae, Meng, Fan-Rui, White, Barry, Bhatti, Jagtar S. och Arp, Paul A. (2011). Modelling and mapping topographic variations in forest soils at high resolution: A case study. *Ecological Modelling*, 222(14), s. 2314–2332, doi:10.1016/j.ecolmodel.2011.01.003.
- Naghdi, Ramin, Solgi, Ahmad, Labelle, Eric R. och Zenner, Eric K. (2016). Influence of ground-based skidding on physical and chemical properties of forest soils and their effects on maple seedling growth. *European Journal of Forest Research*, 135(5), s. 949–962, doi:10.1007/s10342-016-0986-3.
- Naturskyddsföreningen (2025). *Skog i Uppsala län*. <https:// uppsala-lan.naturskyddsforeningen.se/uppsala-lan-idag/skog-i-uppsala-lan/> [Hämtad: 2025-03-31].
- Nordfjell, Tomas (2020). *Skogsavverkning och markskador*. Umeå: Sveriges lantbruksuniversitet Institutionen för Skogens Biomaterial och Teknologi. https://www.slu.se/globalassets/ew/org/inst/skmsk/nordfjell.2020.skogsmaskinermarkskador_erasmusplus_o2-002.pdf [Hämtad: 2025-05-08].
- Oltean, Gabriel S., Comeau, Philip G. och White, Barry (2016). Linking the Depth-to-Water Topographic Index to Soil Moisture on Boreal Forest Sites in Alberta. *Forest Science*, 62(2), s. 154–165, doi:10.5849/forsci.15-054.
- Qin, C., Zhu, A. X., Pei, T., Li, B., Zhou, C. och Yang, L. (2007). An adaptive approach to selecting a flow-partition exponent for a multiple-flow-direction algorithm. *International journal of geographical information science : IJGIS*, 21(4), s. 443–458, doi:10.1080/13658810601073240.
- Qin, Cheng-Zhi, Zhu, A.-Xing, Pei, Tao, Li, Bao-Lin, Scholten, Thomas, Behrens, Thorsten och Zhou, Cheng-Hu (2011). An approach to computing topographic wetness index based on maximum downslope gradient. *Precision Agriculture*, 12(1), s. 32–43, doi:10.1007/s11119-009-9152-y.
- Ring, Eva, Ågren, Anneli M., Lidberg, William, Johansson, Fredrik, Bergkvist, Isabelle och Högbom, Lars (2021). *A guide on how to use wet area maps in forestry*. arbetsrapport No. 1072–2021. https://www.skogforsk.se/cd_20210302175527/contentassets/659d20dd832842128ce71254c99d2dfd/arbetsrapport-1072-2021.pdf.
- SCB (2023). *Marken i Sverige*. Statistikmyndigheten SCB. <https://www.scb.se/hitta-statistik/sverige-i-siffror/miljo/marken-i-sverige/> [Hämtad: 2025-03-06].
- Schönauer, Marian, Hoffmann, Stephan, Maack, Joachim, Jansen, Martin och Jaeger, Dirk (2021). Comparison of Selected Terramechanical Test Procedures and Cartographic Indices to Predict Rutting Caused by Machine Traffic during a Cut-to-Length Thinning Operation. *Forests*, 12(2), s. 113, doi:10.3390/f12020113.
- Schönauer, Marian, Väättäinen, Kari, Prinz, Robert, Lindeman, Harri, Pszenny, Dariusz, Jansen, Martin, Maack, Joachim, Talbot, Bruce, Astrup, Rasmus och Jaeger, Dirk (2021). Spatio-temporal prediction of soil moisture and soil strength by depth-to-water maps. *International Journal of Applied Earth Observation and Geoinformation*, 105, s. 102614,

doi:10.1016/j.jag.2021.102614.

- SGI (2023). *Jords tekniska egenskaper*. Statens geotekniska institut.
<https://www.sgi.se/sv/Forskning--larande/om-geoteknik-och-miljogeoteknik/geoteknik-och-markmiljo/jordmateriallara/jords-tekniska-egenskaper/> [Hämtad: 2025-05-08].
- SGU (2023). *SGUs Kartvisare*. <https://apps.sgu.se/kartvisare/kartvisare-jordarter-25-100.html> [Hämtad: 2025-05-13].
- SGU (2024a). *jordarter-25-100000-beskrivning*.
<https://resource.sgu.se/dokument/produkter/jordarter-25-100000-beskrivning.pdf> [Hämtad: 2025-03-21].
- SGU (2024b). *Jorddjupsdata*.
<https://www.sgu.se/produkter-och-tjanster/geologiska-data/jordarter--geologisk-data/jorddjupsdata/> [Hämtad: 2025-03-28].
- Skogsstyrelsen (2025). *Skogliga grunddata - produktbeskrivning*.
<https://www.skogsstyrelsen.se/globalassets/sjalvservice/karttjanster/geodatatjanster/produktbeskrivningar/raster-skogliga-grunddata---produktbeskrivning.pdf> [Hämtad: 2025-03-21].
- SLU (2020). *Produktbeskrivning: SLU Markfuktighetskarta version 1.0*.
<https://www.skogsstyrelsen.se/globalassets/sjalvservice/karttjanster/geodatatjanster/produktbeskrivningar/markfuktighetskarta-slu---produktbeskrivning.pdf> [Hämtad: 2025-04-12].
- SLU (2024). *Torvkarta*. SLU.
<https://www.slu.se/miljoanalys/statistik-och-miljodata/sok-data/torvkarta/> [Hämtad: 2025-03-28].
- SMHI (2025). *Normalkartor*. SMHI. <https://www.smhi.se/klimat/klimatet-da-och-nu/normalkartor> [Hämtad: 2025-04-01].
- Uusitalo, Jori, Ala-Ilomäki, J., Lindeman, Harri och Toivio, Jenny (2019). Modelling soil moisture – soil strength relationship of fine-grained upland forest soils. *The Finnish Society of Forest Science*, 53(1), doi:10.14214/sf.10050.
- Uusitalo, Jori, Salomäki, Marika och Ala-Ilomäki, Jari (2015). Variation of the factors affecting soil bearing capacity of ditched pine bogs in Southern Finland. *Scandinavian Journal of Forest Research*, 30(5), s. 429–439, doi:10.1080/02827581.2015.1012110.
- White, Barry, Ogilvie, Jae, Campbell, David M. H. M. H., Hiltz, Douglas, Gauthier, Brian, Chisholm, H. Kyle H., Wen, Hua Kim, Murphy, Paul N. C. N. C. och Arp, Paul A. A. (2012). Using the Cartographic Depth-to-Water Index to Locate Small Streams and Associated Wet Areas across Landscapes. *Canadian Water Resources Journal / Revue canadienne des ressources hydriques*, 37(4), s. 333–347, doi:10.4296/cwrj2011-909.
- Wikipedia (2024). *California bearing ratio - Wikipedia*. Wikipedia.
https://en.wikipedia.org/wiki/California_bearing_ratio#cite_note-7 [Hämtad: 2025-04-10].
- Zhao, Min, Liu, Shaohua, Sun, Yarong och Chen, Yunming (2023). Does stand density affect understory vegetation and soil properties of differently aged *Robinia pseudoacacia* plantations? *Forest Ecology and Management*, 548, s. 121444, doi:10.1016/j.foreco.2023.121444.
- Zou, Xuan, Li, Dianqing, Wang, Shun, Gu, Shixiang och Wu, Wei (2024). Instability and deformation behaviors of root-reinforced soil under constant shear stress path. *Engineering Geology*, 343, s. 107762, doi:10.1016/j.enggeo.2024.107762.
- Ågren, A. M., Lidberg, W., Strömberg, M., Ogilvie, J. och Arp, P. A. (2014). Evaluating digital terrain indices for soil wetness mapping – a Swedish case study. *Hydrology and Earth System Sciences*, 18(9), s. 3623–3634, doi:10.5194/hess-18-3623-2014.
- Ågren, Anneli (2023). *Om SLU Markfuktighetskarta*. SLU.SE.
<https://www.slu.se/institutioner/skogens-ekologi-skotsel/forskning2/markfuktighetskarta/o-m-slu-markfuktighetskarta/> [Hämtad: 2025-04-12].
- Ågren, Anneli M., Larson, Johannes, Paul, Siddhartho Shekhar, Laudon, Hjalmar och Lidberg, William (2021). Use of multiple LIDAR-derived digital terrain indices and machine learning for high-resolution national-scale soil moisture mapping of the Swedish forest landscape.

Geoderma, 404, s. 115280, doi:10.1016/j.geoderma.2021.115280.

Ågren, Anneli M., Lidberg, William och Ring, Eva (2015). Mapping Temporal Dynamics in a Forest Stream Network—Implications for Riparian Forest Management. *Forests*, 6(9), s. 2982–3001, doi:10.3390/f6092982.

Appendix

Bilaga A. Steg för hydrologisk bearbetning och generering av DTW-karta


Tabell 2. Översikt över geospatiala verktyg och parametrar som använts för hydrologisk bearbetning av digitala höjdmodellen och generering av DTW-kartan. Tabellen redovisar program, verktyg, indata, utdata samt specifika val i verktygen.

Program	Verktyg	Input	Output	Parametrar
QGIS	BreachSingleCellPits (WhiteboxTools)	DEM 1+	BSC	
	FillSingleCellPits (WhiteboxTools)	BSC	FSC	
	FeaturePreserve Smoothing (WhiteboxTools)	FSC	FPS	Filter=11 Normdiff=15 Numiter=3 Maxdiff=0.3 Zfactor=none
	BreachDepressionLeastCost (WhiteboxTools)	FPS	DEMBreach	Maxdist=20 Maxcost=none Mindist=true, Flatincrement=0.000001

				Fill=true D8pointer=true
ArcGis Pro	Flow Direction (Spatial Analyst Tools)	DEMBreach	Flowdir	Flow direction type= D8 Force all edge cells to flow outward=true
	Flow accumulation (Spatial Analyst Tools)	Flowdir	Flowacc	Output data type=integer Input flow direction type = D8
	Build Raster Attribute Table (Data Management Tools)	Flowacc		Overwrite=true
	Set Null (Spatial Analyst Tools)	Flowacc	SetNull	Expression: value <= 10000 Input false raster or constant value=1
	Stream to Feature (Spatial Analyst Tools)	Input stream: SetNull Input flow direction: Flowdir	Stream	Simplify polylines= false
	Slope	DEM 1+	Slope	Output measurement = degree

	(Spatial Analyst Tools)		Method=planar Zfactor=1 Target device for analysis= GPU then CPU
	Raster calculator (Spatial Analyst Tools)	SlopeCost	Map algebra expression: $\text{Tan}(\text{Slope} * (3.14/180)) * 1^2$
	Path Distance (Spatial Analyst Tools)	Input source: Stream Input cost: Slopecost	DTW

Bilaga B. Samband mellan valda variabler och CBR



Figur 16. Pairplot-figur som visar samband mellan alla valda variabler. Färgkodade mätpunkter för varje jordart (sand, ler-silt och morän) som illustrerar jordarters sambands styrka och riktning.

Bilaga C. Modellekvationer från regressionsmodellering

Tabell 3. Modellekvationer för modeller från regressionsmodellering med ingående variabler och regressionskoefficienter.

Modell	Ekvationsnummer	Ekvation
Basmodell klassificerad DTW	(5)	$\log(CBR) = 0.33 + 0.3573DTW_{Torr} + 0.1817JA_{LerSilt} + 0.1159JA_{Morän} - 0.2589(DTW_{Torr}:JA_{LerSilt}) - 0.1428(DTW_{Torr}:ST_{Morän})$
Basmodell kontinuerlig DTW	(6)	$\log(CBR) = 0.4306 + 0.1817DTWI + 0.2026JA_{LerSilt} + 0.1221JA_{Morän} + 0.0761(DTWI:JA_{LerSilt}) - 0.0549(DTWI:JA_{Morän})$
Basmodell kontinuerlig DTW samt alla alternativa variabler	(7)	$\log(CBR) = 0.3431 + 0.0639DTWI + 0.0562(DTWI:JAm_{LerSilt}) - 0.0199(DTWI:JAm_{Morän}) + 0.0846STm_{LerSilt} + 0.1238STm_{Morän} + 0.0328L70 - 0.0004VF + 0.0075JD$
Alla förklarande variabler utan interaktion DTW*JAm	(8)	$\log(CBR) = 0.3467 + 0.0668DTWI + 0.1507JAm_{LerSilt} + 0.0970JAm_{Morän} + 0.0320L70 - 0.0004VF + 0.0067JD$
SLU:s markfuktighetskartor och kartbaserad jordart	(9)	$\log(CBR) = 0.9031 - 0.0125MF - 0.2597JAm_{LerSilt} - 0.1590JAm_{Morän} + 0.0097(MF:JAm_{LerSilt}) + 0.0060(MF:JAm_{Morän})$
DTW och fältbestämd jordart	(10)	$\log(CBR) = 0.2631 + 0.0934DTWI + 0.1972JAf_{LerSilt} + 0.3836JAf_{Morän} - 0.0730(DTWI:JAm_{LerSilt}) - 0.0456(DTWI:JAm_{Morän})$
SLU:s markfuktighetskartor och fältbestämd jordart	(11)	$\log(CBR) = 0.8586 - 0.0122MF - 0.3140JAf_{LerSilt} + 0.0417JAf_{Morän} + 0.0107(MF:JAm_{LerSilt}) + 0.0062(MF:JAm_{Morän})$