ARBETSRAPPORT 1286–2026

Fukthaltsprognoser för vältlagrad grot

– baserade på öppna väderdata och skogsföretagens driftdata

Siri Westerblom och Raul Fernandez Lacruz



En täckt grotvälta vid vägkant. Bild: Astrid Bygge.

skogforsk

Innehåll

Förord **4**

Summary **5**

Sammanfattning **6**

Introduktion **7**

Syfte 10

Material och metod **11**

Dataunderlag 11

Databearbetning 13

Variabelanalys 14

Modellutveckling 14

Linear mixed-effect model (LME) 14

Generalized additive model (GAM) 15

Random Forest (RF) 15

Regionala och lokala modeller 15

Utvärdering av modeller 16

Resultat **18**

Modell 1: Linear mixed-effect model 18

Modell 2: Generalized additive model 19

Modell 3: Random Forest 20

Jämförelse av modellerna 21

Diskussion **24**

Osäkerhetskällor i indata 25

Slutsatser **26**

Referenser **27**

Bilagor **30**

Bilaga A: Korrelationsanalys 30

Bilaga B: Linear mixed-effect model 31

Bilaga C: Generalized additive model 33

Bilaga D: Random Forest 37



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

Kvalitetsgranskning (Intern peer review) har genomförts i oktober 2026 av
Maria Iwarsson Wide, Programchef. Därefter har Magnus Thor, Forskningschef,
granskat och godkänt publikationen för publicering 16 november 2026.

Redaktör: Anna Franck, anna@annafranck.se
©Skogforsk 2026 ISSN 1404-305X

Förord

Denna studie har genomförts inom projektet *Förbättrade grotprognoser för precisionsplanering* som pågått mellan 2023 och 2026. Projektet har bedrivits av Skogforsk och finansierades av Energimyndigheten via forskningsprogrammet Bio+ (projektnummer 2023–01054) och projektparterna Jämtkraft, Holmen Skog, Mellanskog, Stora Enso, Sveaskog, Södra och Vattenfall.

Författarna riktar ett stort och varmt tack till alla som varit delaktiga och på olika sätt bidragit till att detta arbete kunnat genomföras.

Uppsala och Sävar i oktober 2026

Siri Westerblom och Raul Fernandez Lacruz

Summary

Forest residues (logging residues, comprising tops and branches) constitute an important feedstock for the Swedish bioenergy sector. The moisture content of forest residues strongly influences their energy content, with lower moisture levels resulting in a higher fuel heating value. Moisture content affects financial payments, transportation efficiency, and combustion and operation in power plants, thereby creating a need for reliable predictions of moisture content at the point of delivery. Previous research in this field has largely focused on process-based models that describe the physical processes governing drying and rewetting of residues during storage. However, such models often require detailed input data that are not readily available in operational forestry systems, limiting their practical applicability.

The aim of this study was to investigate factors associated with the moisture content of forest residues stored in windrows at roadsides, and to assess the potential for developing data-driven prediction models. Rather than modelling the underlying physical processes directly, a statistical modelling approach was evaluated using existing operational and weather data.

The analysis was based on approximately 10,000 deliveries of forest residues from southern and central Sweden, delivered over seven winter seasons. Three modelling approaches were evaluated: a Linear Mixed-Effects Model (LME), a Generalized Additive Model (GAM), and Random Forest. Despite relying solely on aggregated operational and weather variables without detailed information on local storage conditions or residue handling practices, all models explained a substantial proportion of the observed variation in moisture content. Random Forest achieved the highest predictive performance, explaining approximately 50% of the variation in observed moisture content in the regional model, and up to 60% in some local models. However, predictions in all models remained associated with considerable uncertainty and tended to regress toward the mean, resulting in underestimation of high moisture levels and overestimation of low moisture levels.

Weather conditions prior to forwarding and delivery, particularly temperature and precipitation, were identified as important explanatory variables. Weather conditions during the summer preceding delivery also had a substantial influence. The GAM revealed clear seasonal patterns, with lower moisture content predicted for residues forwarded during summer than for those forwarded during the winter season. Model performance also varied geographically. Some regions, most notably the eastern coastal areas of Sweden, could be modelled more accurately than others, suggesting that local factors not captured in available registry and operational data may play an important role in determining moisture content.

The results demonstrate that a substantial proportion of the variation in moisture content of forest residues can be explained using existing operational and weather data, and that a data-driven statistical approach has considerable potential for moisture content forecasting. At the same time, the findings indicate that local conditions and uncertainties in input data limit predictive performance and that extreme moisture levels remain particularly difficult to predict. Future work should therefore focus on improving data quality, developing more representative moisture-content measurements, and incorporating additional information on storage and handling conditions.

Sammanfattning

Skogsbränslen som grenar och toppar (grot) utgör en viktig råvara för den svenska bioenergisektorn. Fukthalten i groten påverkar bränslets energiinnehåll, där en lägre fukthalt innebär ett högre värmevärde. Fukthalten har därmed betydelse för ekonomisk ersättning, transporteffektivitet och värmeverkens drift, vilket skapar ett behov av tillförlitliga prognoser för grotens fukthalt vid leverans. Tidigare forskning inom detta område har ofta utgått från processbaserade modeller som beskriver de fysikaliska processerna vid uttorkning och återfuktning under lagring. Dessa modeller är ofta beroende av detaljerade indata som inte finns tillgängliga i den operativa verksamheten, vilket försvårar den praktiska användningen.

Syftet med studien var att analysera sambandet mellan faktorer som kan påverka fukthalten i vältlagrad grot samt att undersöka möjligheterna att utveckla datadrivna modeller för prediktion av fukthalt. I stället för att beskriva de underliggande fysikaliska processerna prövades ett statistiskt angreppssätt där befintliga drift- och väderdata användes för att modellera fukthalten.

Analysen baserades på cirka 10 000 grotleveranser från Götaland, Svealand och södra Norrland levererade över sju vintersäsonger. Tre modellansatser utvärderades: linjär mixad modell (LME), generaliserad additiv modell (GAM) och Random Forest. Trots att modellerna enbart baserades på övergripande drift- och väderdata, utan detaljerad information om lokala lagringsförhållanden eller hantering av groten, visade resultaten att samtliga modeller kunde fånga betydande delar av variationen i fukthalt. Random Forest gav bäst prediktionsförmåga och förklarade regionalt cirka 50 procent av variationen i observerad fukthalt, och upp till 60 procent i vissa lokala områden. Prediktionerna var dock förknippade med betydande osäkerheter och tenderade att dras mot medelvärdet, vilket innebar att höga fukthalter underskattades och låga fukthalter överskattades.

Väderförhållanden före skotning och inmätning, särskilt temperatur och nederbörd, identifierades som viktiga förklaringsfaktorer. Även väderförhållandena under den senaste sommaren före leverans hade stor betydelse. Dessutom visade GAM-modellen tydliga säsongsmönster, där fukthalten exempelvis skattades vara lägre för grot som skotades under sommaren än för grot som skotades under vinterhalvåret. Resultaten visade även att modellernas prediktionsförmåga varierade mellan olika geografiska områden. Vissa regioner kunde modelleras betydligt bättre än andra, framför allt östkusten, vilket tyder på att lokala förhållanden som inte fångas i tillgängliga registerdata kan ha stor betydelse för fukthalten.

Studien visar att en betydande del av variationen i grotens fukthalt kan förklaras med hjälp av befintliga drift- och väderdata, och att ett datadrivet statistiskt angreppssätt har potential att prognostisera fukthalt. Samtidigt tyder resultaten på att lokala förhållanden och osäkerheter i indata begränsar prediktionsförmågan, och att extremvärden är särskilt svåra att fånga. Fortsatt utveckling bör därför fokusera på förbättrad datakvalitet, mer representativa fukthaltsmätningar samt kompletterande information om lagrings- och hanteringsförhållanden.

Introduktion

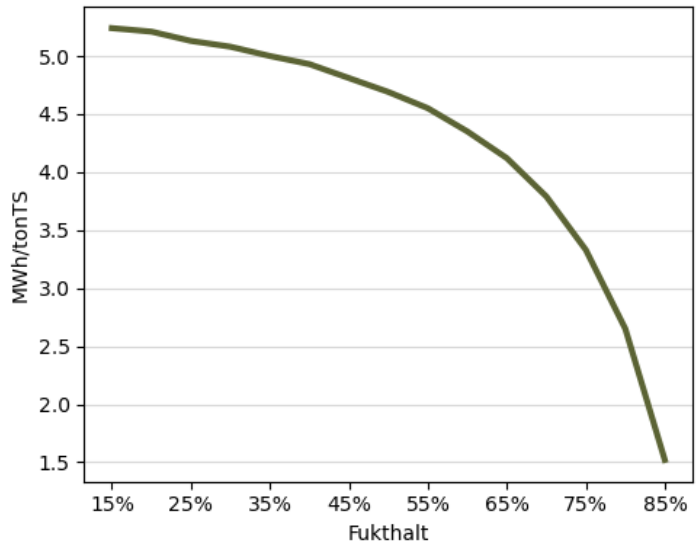
Bioenergi är ett av Sveriges största energislag och utgjorde omkring 25 procent (135 TWh) av den totala energitillförseln i landet under 2024 (Energimyndigheten 2025). Cirka 80 procent av bioenergin har sitt ursprung i restprodukter från skogssektorn (Björheden & Eckerberg 2024), där en betydande del utgörs av avverkningsrester, det vill säga grenar och toppar (grot) från slutavverkning. Skördaren och skotaren använder vid behov grot för att köra på i stick- respektive basvägar vid avverkning, i syfte att undvika markskador, men vid lönsamma förhållanden kan groten tas ut och nyttjas som bränsle i värme- och kraftvärmeverk.

När uttag av grot planeras på en avverkningstrakt samlas materialet redan under avverkningen i mindre högar på hygget (grotanpassas), vid sidan av stickvägarna bredvid rundvirket. Därefter kan det antingen skotas ut direkt efter avverkning (grön grot) eller lämnas kvar på hygget för att torka och barra av (brun grot). Den senare hanteringen är vanligast i praktiken och rekommendationen sedan 1980-talet är att låta groten torka och barra av på hygget över en sommarsäsong. Efter lagringsperioden skotas materialet till en välta i anslutning till bilväg. Rekommendationen är att skota när både mark och grot är så torra som möjligt, samt att täcka vältan med armerad papp för att minska risken för återvätning (Skogforsk 2023a). Andra rekommendationer är att välja en plats med bra förutsättningar för torkning, till exempel torrt underlag med sol- och vindexponering (Skogskunskap 2024). Lagringstiden på hygget och vid vältan varierar från några dagar till flera år beroende på bland annat efterfrågan, torkningsförhållanden och transportavstånd till mottagande anläggning. Inför användning flisas materialet och transporteras därefter till energikunden direkt eller via terminaler (Figur 1). Groten kan också transporteras som hel grot och flisas då i stället vid terminal eller kund.

Grotens energiinnehåll (värmevärde) är i stort sett beroende av dess fukthalt (Figur 2). Fukthalten betraktas som en av grotens viktigaste kvalitetsegenskaper, eftersom en lägre fukthalt i materialet innebär en högre torrhalt och därmed ett högre energiinnehåll (Skogskunskap 2025). Då ersättningen för grotflisen vanligtvis baseras på levererad energimängd bestäms vikten och fukthalten vid leverans till energikunden (Biometria 2026). Färsk grot har normalt en fukthalt på cirka 50–55 procent (Lehtikangas 1999), medan fukthalten vid leverans efter lagring i genomsnitt uppgår till omkring 35–45 procent, beroende på geografisk plats och variationer mellan år (Parklund 2023). En låg fukthalt i det levererade materialet är därför önskvärt för leverantörerna, både ur ett ekonomiskt perspektiv och för att öka energieffektiviteten i värdekedjan.

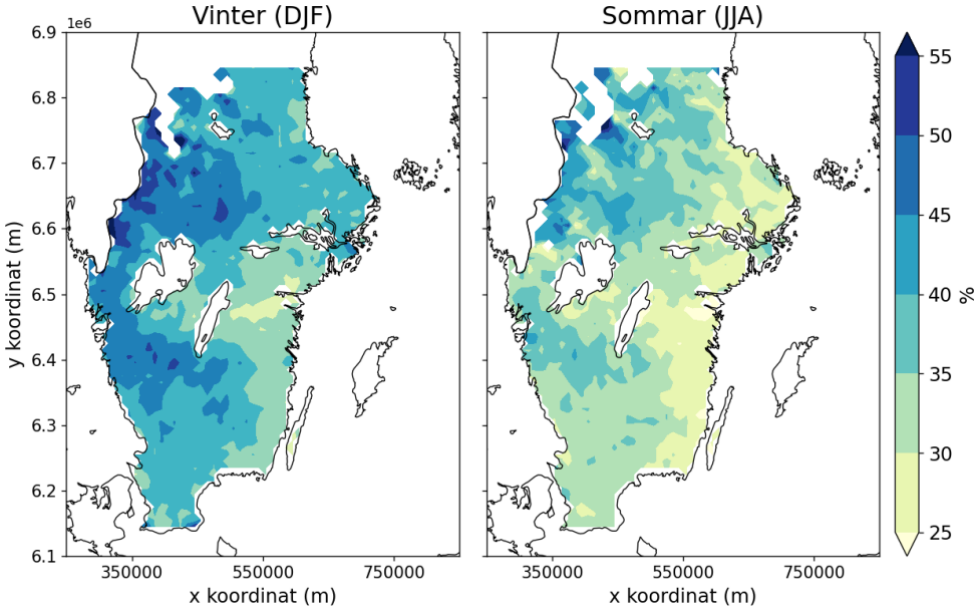


Figur 1. Typexempel på grothantering och värdekedja (AI genererad-bild).



Figur 2. Samband mellan värmevärde i megawattimmar (MWh) per ton torrsubstans (TS) och fukthalt i grotflis, med antagen askhalt på 2,5 procent. Data från beräkningsverktyget WeCalc (Skogforsk 2026).

Tidigare undersökningar har visat att fukthalten i grot påverkas av flera väderrelaterade faktorer, däribland torkningsförhållanden under sommarhalvåret, väderförhållanden under lagring och hantering, samt tidpunkten för inmätning. Grot som mäts in under vinterhalvåret uppvisar generellt högre fukthalt än grot som mäts in under sommarhalvåret (Erlandsson 2008, Eriksson m.fl. 2025) (Figur 3). Tidpunkten för leverans styrs dock i hög grad av energikundernas efterfrågan, som är nära kopplad till utomhustemperaturen och därför är störst under vinterhalvåret. Därmed är det inte möjligt att anpassa leveranserna så att all grot mäts in under sommarhalvåret i syfte att uppnå lägre fukthalter.



Figur 3. Rumslig fördelning av genomsnittlig inmätt fukthalt (%) i grot under vinter (Dec, Jan, Feb) och sommar (Jun, Jul, Aug). Kartorna visar medelvärden för perioden 2013–2023.

Sedan flera år tillbaka använder flera skogsföretag (det vill säga leverantörer av grot) ett prognossystem utvecklat av Skogforsk för uppskattning av grotens position och mängd på hygget (Möller m.fl. 2009, Fernandez-Lacruz m.fl. 2026). Däremot saknas idag prognosverktyg för kvalitetsegenskaper såsom fukthalt. Eftersom fukthalten påverkar energiinnehållet och därmed de framtida intäkterna för leverantörerna, skulle en indikation på fukthalten vara värdefull för att förbättra planering och styrning av försörjningskedjan. Även energianläggningarna har behov av information om bränslets fukthalt för att kunna optimera förbränningen, eftersom olika anläggningar ställer olika krav på materialets fukthalt. I dagsläget blir fukthalten känd först i efterhand när bränslet har levererats och många gånger redan förbränts. Detta beror på att referensmetoden för bestämning av fukthalt, SS-EN ISO 18134-2:2024 (SIS 2024), bygger på vägning och torkning av prover tills att konstant vikt uppnås. För grotflis krävs i praktiken ofta minst 24 timmars torkning innan analysen kan slutföras. Kvalitetskrav från energikunderna fortsätter vara centrala enligt nya undersökningar av Andersson (2025) och Thorngren (2025).

Referensmetoden upprätthåller hög precision men utmaningen är att säkerställa att proverna är representativa för den aktuella leveransen (lasten i bilen) och för hela partiet (avverkningsobjekt eller virkesorder). Provtagningen bör anpassas enligt Biometrias anvisningar för bestämning av torrhalt och energiinnehåll på skogsråvara (Biometria 2026) så att tillräcklig mätnoggrannhet uppnås i enlighet med Skogsstyrelsens noggrannhetskrav. Osäkerheten (medelfelet) i de uppmätta fukthalterna beror på hur många leveranser (lastbilar) partiet omfattar, hur många lastbilar som provtas och hur många prov som tas per lastbil.

Under det senaste decenniet har flera forskningsansatser genomförts i syfte att prognostisera fukthalten i hygges- och vältlagrad grot med hjälp av väderdata (Acuna m.fl. 2012, Erber m.fl. 2014, Wilhelmsson m.fl. 2015, Routa m.fl. 2016, Lindblad m.fl. 2018, Lennartsson 2022). Den praktiska tillämpningen av dessa fukthaltsmodeller ställs dock inför flera utmaningar. Modellerna har ofta utvecklats utifrån enskilda försök och bygger på relativt begränsade datamängder från specifika geografiska områden och tidsperioder. Detta medför att de ofta inte är representativa och applicerbara för nya områden utanför studien. Dessutom baseras modellerna ofta på detaljerad information om både materialets egenskaper och väderförhållandena under hela lagringsperioden. Exempel på sådana data är kontinuerliga mätningar av viktförändringar med hjälp av lastceller, lokala väderstationer placerade i anslutning till vältan eller detaljerad information om vältans storlek, placering och exponering för väder. Denna typ av data är i regel inte tillgänglig i den operativa hanteringen av skogsbränslen.

Vidare är den initiala fukthalten i groten okänd och substansförluster på grund av biologisk nedbrytning och avbarrning under lagring kan påverka förloppet. Grotens heterogena struktur innebär dessutom att olika delar av vältan kan uppvisa olika torkbeteenden. Is och snö kan blandas in i vältan och flisen under lagring och hantering, vilket bidrar till variation i uppmätt fukthalt för olika leveranser från samma välta och lagringsplats (Fernandez-Lacruz & Bergström 2017). Många tidigare forskningsansatser har syftat till att fysikaliskt beskriva torkningsförloppet dag för dag under hela lagringsperioden, något som försvåras av de ovan nämnda osäkerheterna.

Syfte

Syftet med denna studie var att analysera sambandet mellan faktorer som kan påverka fukthalten i vältlagrad grot samt att undersöka möjligheterna att utveckla datadrivna modeller för prediktion av fukthalt.

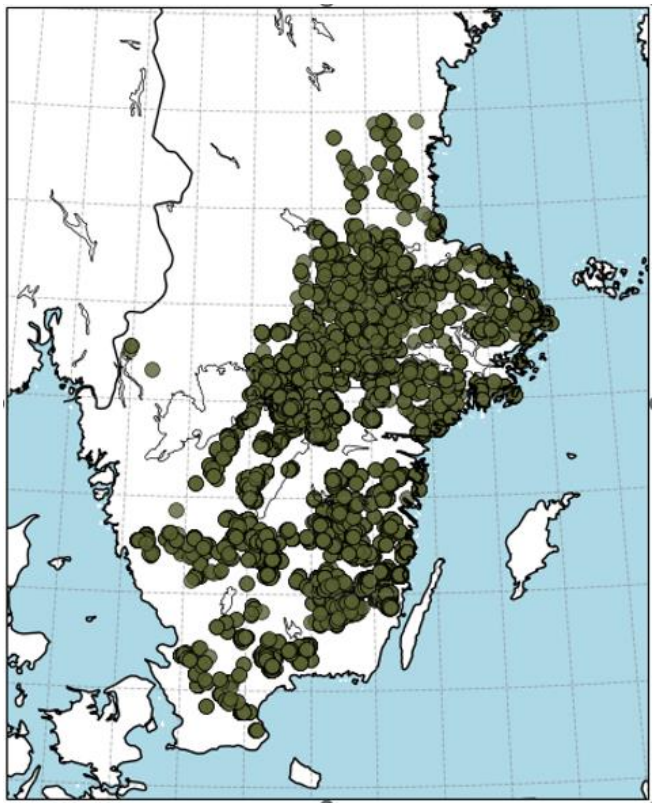
Till skillnad från tidigare processbaserade modeller, som syftat till att beskriva de fysikaliska processerna bakom grotens torkning och återfuktning, bygger denna studies angreppssätt på statistiska samband i historiska data. Modellerna baserades på öppna väderdata och andra lättillgängliga variabler som redan i dag används eller finns tillgängliga inom skogsföretagens operativa verksamhet, utan behov av särskilda mätningar eller beräkningar.

Material och metod

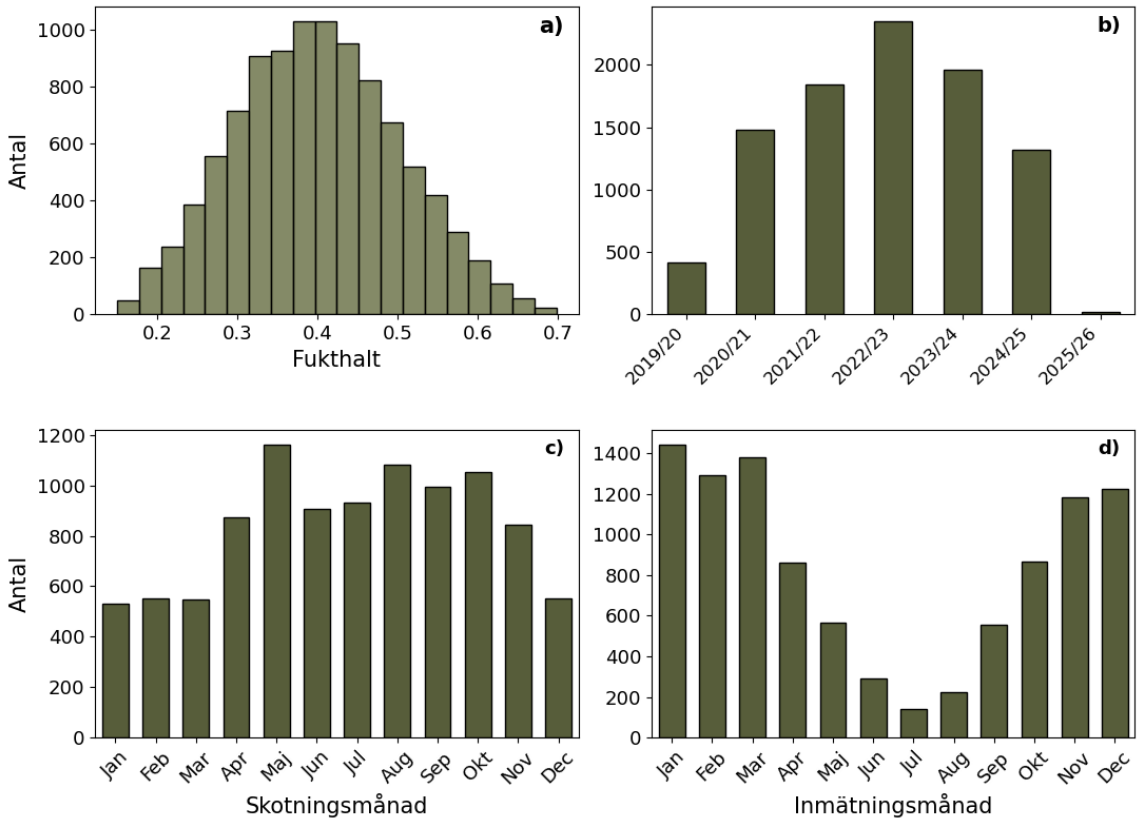
Dataunderlag

Det tillgängliga datamaterialet omfattade 10 037 leveranser (lastbilslass) av grot från 3 095 utförda avverkningar (virkesordrar) i Götaland, Svealand och Södra Norrland (Figur 4). Geografisk täckning saknades dock i vissa områden, bland annat längs västkusten samt i Dalsland, Värmland och Dalarna. Datamaterialet omfattade leveranser av grotflis från sju vintersäsonger (från 2019/2020 t.o.m. 2025/2026) från deltagande skogsbränsleleverantörer i projektet *Förbättrade grotprognoser för precisionsplanering* (Skogforsk 2023b). De inmätta leveranserna uppvisade en genomsnittlig fukthalt på 0,401. Fukthalten varierade dock kraftigt mellan leveranserna och var ungefär normalfördelad kring medelvärdet, med ett lägsta observerat värde på 0,151 och ett högsta på 0,698 (Figur 5). Figur 5 visar även att skotning förekom under hela året men var något vanligare under sommarhalvåret, medan inmätningarna (grotleveranserna) var tydligt koncentrerade till vinterhalvåret. Lagringstid på hygge och tiden i välta varierade stort mellan leveranserna, från några få dagar upp till flera år. Merparten av observationerna var koncentrerade till cirka 100–400 dagar på hygge och 100–500 dagar i välta (Figur 6).

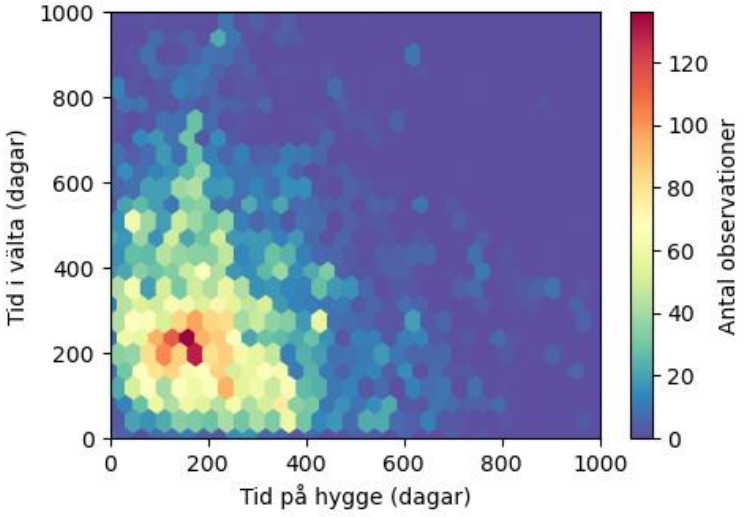
För varje leverans fanns uppgifter om uppmätt fukthalt vid mottagare, virkesordernummer, koordinater för avverkningsplats (därmed den ungefärliga lagringsplatsen för groten), samt datum för avverkning, grotskotning och inmätning. I praktiken kan ett virkesordernummer omfatta grot från en eller flera vältor, placerade nära varandra, men de kan också vara geografiskt åtskilda med flera hundra meter.



Figur 4. Placering av slutavverkningarna och därmed grotens ursprung och ungefärliga lagringsplats.



Figur 5. Fördelning av inmätt fukthalt (a), antal grotleveranser per vintersäsong (b), skotningsmånad (c) och inmätningsmånad (d).



Figur 6. Hexbin-diagram som visar sambandet mellan tid på hygge och tid i välta för de analyserade grotpartierna. Färgerna anger antalet observationer inom respektive hexagon, där varmare färger motsvarar högre observationsdensitet. Den största koncentrationen av observationer återfinns vid cirka 100–200 dagar på hygge och 100–300 dagar i välta.

Databearbetning

Utifrån datum för avverkning, grotskotning och inmätning kunde lagringstider beräknas i form av antal dagar på hygge, i välta och totalt för hela lagringsperioden. Datumen för de olika åtgärderna konverterades även till formatet Day of Year (DOY), vilket anger vilken dag på året åtgärden utfördes. Variabeln inkluderades i modelleringen, eftersom tidigare analyser (Eriksson m.fl. 2025) har visat att tidpunkten på året då inmätning och skotning sker, kan ha påverkan på den slutliga fukthalten.

Utifrån datum och koordinater kopplade till respektive virkesordernummer extraherades väderdata för 7 respektive 30 dagar innan varje åtgärd (avverkning, grotskotning och inmätning) för varje leverans. Då sommarens torkperiod också kan påverka fukthalterna extraherades även väderdata för perioden 1 juni till och med 30 september (det vill säga från början av sommaren till tidig höst), under den senaste sommaren innan inmätning.

I studien användes väderdatasetet E-OBS som baseras på observationer från väderstationer som har interpolerats till ett rutnät (Corner R. m.fl. 2018). Datasetet täcker hela Europa och har en spatial upplösning på 0,1° x 0,1° (motsvarande ca 11 km x 11 km) och en temporal upplösning på dygnsnivå. E-OBS laddades ned från Copernicus Climate Services som drivs av ECMWF (European Center for Medium-range Weather Forecasts) (Copernicus Climate Change Service 2020).

För den senaste sommarens väder beräknades en medeltemperatur, en temperatursumma och den kumulativa nederbörden för hela perioden. För vädret 7 respektive 30 dagar innan en utförd åtgärd valdes parametrarna medeltemperatur, medelvindhastighet, relativ luftfuktighet i medeltal samt den kumulativa nederbörden för perioden. En slutgiltig lista av tillgängliga modellvariabler beskrivs i Tabell 1.

Efter att ovanstående variabler beräknats filtrerades samtliga grotlass med negativ lagringstid bort från dataunderlaget, då detta innebär att något av datumen inte stämmer. Sedan valdes att endast arbeta med de vintersäsonger som hade minst 1 000 leveranser, varav samtliga leveranser för vintersäsongerna 2019/2020 och 2025/2026 filtrerades bort. Efter filtrering återstod 9 482 datapunkter.

Tabell 1: Tillgängliga modellvariabler för studien med dess beskrivning.

Variabel	Beskrivning
Fukthalt	Andel fukt i grotflis (0–1)
Virkesordernummer	ID för avverkningen, håller samman grotleveranser från samma plats.
Koordinater	x- och y-koordinat (SWEREF99) för hygget från vilket groten härstammar och lagrats vid.
Datum*: Avverkning* *Skotning* *Inmätning*	Datum för avverkning. Datum för skotning till välta vid väg. Datum för inmätning av flis.
Lagringstid	Antal dagar groten lagrats i skogen: totalt, i småhögar på hygge och i välta vid väg.
Väder*: Nederbörd* *Medeltemperatur* *Relativ luftfuktighet* *Vindhastighet*	Kumulativ nederbörd, relativ luftfuktighet, medelvindhastighet och medeltemperatur 7 respektive 30 dagar innan avverkning, skotning och inmätning.
Sommar: *Nederbörd* *Temperatur*	Kumulativ nederbörd, Medeltemperatur och Temperatursumma för den senaste torksommaren, jun–sep.

Variabelanalys

Totalt identifierades 47 potentiella förklarande variabler för modellering av fukthalt. Flera av dessa kunde inte inkluderas samtidigt på grund av hög inbördes korrelation eller överlappande informationsinnehåll. Detta gällde exempelvis vädervariabler beräknade över olika tidsperioder före åtgärd (7 respektive 30 dagar). Variablerna *LagringTotalt*, *LagringHygge* och *LagringVälta* uppvisade dessutom ett direkt beroendeförhållande, eftersom två av variablerna tillsammans definierar den tredje.

Innan modelleringsarbetet påbörjades genomfördes därför en enkel korrelationsanalys mellan samtliga förklarande variabler och responsvariabeln fukthalt. Analysen användes för att identifiera variabler med signifikanta samband med fukthalten som stöd vid val mellan alternativa variabler som beskrev samma underliggande process. När flera variabler bedömdes representera samma process prioriterades i regel den variabel som uppvisade starkast samband med fukthalten.

Korrelationsanalysen genomfördes med Pearsons korrelation (`cor.test`) i R (R Core Team 2026). Då 47 statistiska tester utfördes samtidigt korrigerades p-värdena (`p.adjust`) enligt Benjamini-Hochbergs metod för kontroll av den falska upptäcktsfrekvensen (FDR). Pearsons korrelation användes som ett explorativt mått på linjära samband och inte som ett strikt kriterium för variabelurval, eftersom vissa variabler förväntades uppvisa icke-linjära samband med fukthalten, exempelvis på grund av säsongsvariation. Statistisk signifikans sattes till p-värde <0,05.

Modellutveckling

Modellutvecklingen genomfördes iterativt där flera modellansatser successivt utvecklades och jämfördes. Arbetet inleddes med relativt enkla modeller för att undersöka sambanden mellan de förklarande variablerna och fukthalten, varefter mer flexibla, icke-linjära modellstrukturer utvärderades. Modellernas struktur och variabelurval justerades löpande utifrån modellresultat, diagnostik och variabelsignifikans. Samtliga statistiska analyser och modellanpassningar gjordes i R (R Core Team 2026).

Tre huvudsakliga modellansatser undersöktes: Linear mixed-effect model (LME), Generalized additive model (GAM) samt Random Forest (RF).

Linear mixed-effect model (LME)

Första modellansatsen var en linjär mixad modell (LME), implementerad med funktionen *lmer()* från paketet *lme4*. En LME kan betraktas som en multipel linjär regressionsmodell som, utöver fasta effekter, även inkluderar slumpmässiga gruppeffekter (*random effects*). Slumpmässiga effekter används för att hantera grupperade data där observationer inom samma grupp inte är statistiskt oberoende och därmed förväntas vara mer lika varandra än observationer från olika grupper. Eftersom flera grotlass härstammade från samma avverkning inkluderades *Virkesordernummer* som slumpmässig effekt i modellen. Syftet var att ta hänsyn till den platsbundna variationen i fukthalt och beroende i data.

Eftersom modellen främst var avsedd för prediktion på nya avverkningar användes den slumpmässiga effekten främst för att beskriva beroendestrukturen i data, snarare än för prediktion. Multikollinearitet mellan de fasta effekterna utvärderades även med hjälp av VIF under modellutvecklingen.

Generalized additive model (GAM)

För att undersöka om icke-linjära samband kunde förbättra modelleringen utvecklades därefter generaliserade additiva modeller (GAM) med funktionen *gam()* från paketet *mgcv*. Till skillnad från traditionell linjär regression kan en GAM beskriva komplexa samband genom att ersätta linjära termer med flexibla splinefunktioner.

Valet av variabler som modellerades med splinefunktioner baserades bland annat på granskning av komponent-plus-residualdiagram (`crPlots`) från de linjära modellerna. Särskilt undersöktes om dag på året (*DOY*) samt geografisk position uppvisade icke-linjära samband med fukthalten. Den geografiska effekten modellerades med en tvådimensionell spline baserad på öst-västlig och nord-sydlig koordinat. Även *Virkesordernummer* inkluderades som en splinebaserad random-effect-term.

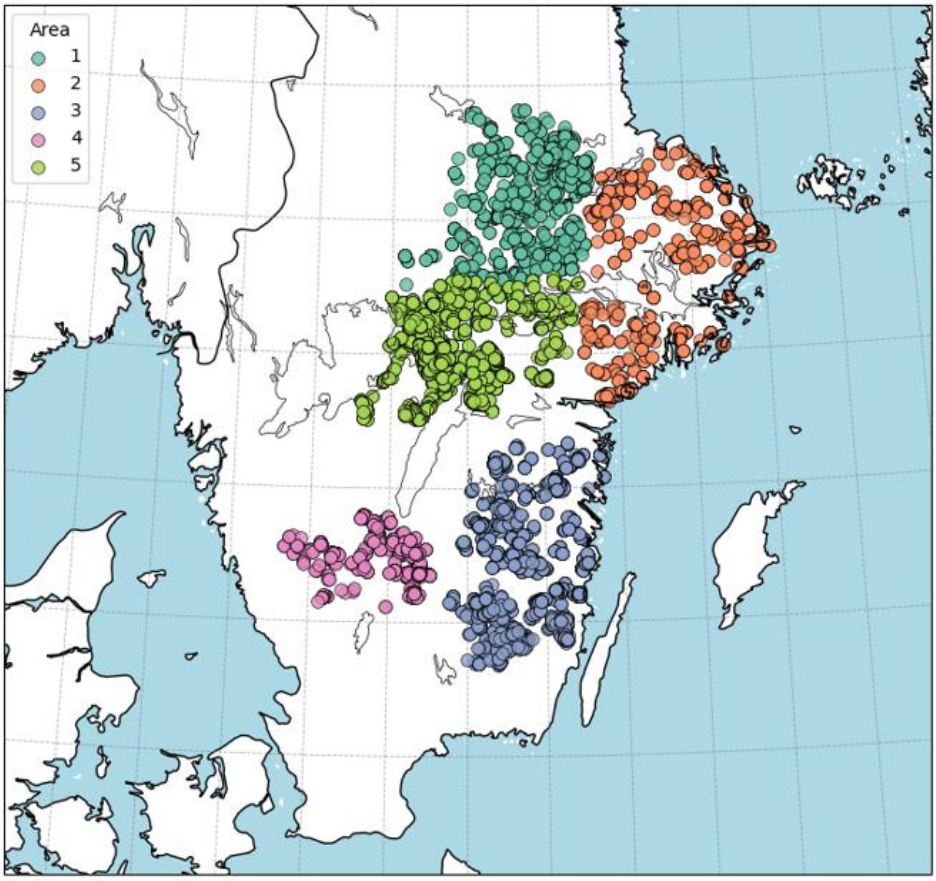
Random Forest (RF)

Som ett tredje steg utvärderades en Random Forest-modell med funktionen *randomForest()* från paketet *randomForest*. Random Forest är en maskininlärnings-metod som bygger en ensemble av ett stort antal beslutsträd och aggregerar deras prediktioner. Metoden kan hantera komplexa icke-linjära samband och interaktioner mellan variabler utan att dessa behöver specificeras i förväg.

Samtliga variabler som valts ut i den inledande variabelscreeningen inkluderades i modellen. Till skillnad från LME- och GAM-modellerna genomfördes därefter inget ytterligare variabelurval baserat på signifikans eller modellförenkling. Modellen byggdes med 500 beslutsträd (ntree = 500), och vid varje split utvärderades slumpmässigt sju förklarande variabler (mtry = 7), vilket motsvarade standardinställningen för regressionsproblem givet antalet inkluderade prediktionsvariabler. Modellens prediktionsförmåga samt variablernas relativa betydelse analyserades därefter och jämfördes med resultaten från LME- och GAM-modellerna.

Regionala och lokala modeller

Samtliga modeller anpassades till hela datamaterialet (9 482 grotlass) för att utveckla en regional modell för Götaland och Svealand. Därutöver utvecklades lokala modeller för att undersöka om en geografiskt mer avgränsad modellering kunde förbättra prediktions-förmågan och öka förklaringsgraden. Fem mindre områden med hög datatäthet definierades för detta ändamål. Områdenas geografiska läge och beskrivning redovisas i Figur 7 respektive Tabell 2.



Figur 7. De fem utvalda områdena och innehållande datapunkter för anpassning av lokala modeller.

Tabell 2. Beskrivning av de fem områdena som användes för att anpassa lokala modeller.

Område	Plats	Datapunkter	Medelfukthalt (%)	Standardavvikelse (p.e.)
1	Inland	1 579	40,0	10,4
2	Östkust	886	36,7	9,9
3	Östkust	2 131	38,0	10,1
4	Inland	671	45,3	10,4
5	Inland	3 420	40,9	9,5

Utvärdering av modeller

Modellerna utvärderades med avseende på både statistisk anpassning och prediktionsförmåga. För LME- och GAM-modellerna granskades residualerna för att bedöma modellantaganden och identifiera eventuella behov av transformationer eller andra justeringar. För LME-modellen beräknades även intraklasskorrelationen (ICC) för att uppskatta hur stor del av variationen i fukthalt som kunde tillskrivas skillnader mellan

avverkningar (slumpeffekten). Under modelleringsarbetet utvärderades respektive modell även med hjälp av modellspecifika mått, däribland marginalt och villkorat R^2 för LME-modeller, justerat R^2 och förklarad devians för GAM-modeller samt andel förklarad variation för random forest-modeller.

Datamaterialet delades sedan slumpmässigt upp i ett träningsdataset (70 procent) och ett testdataset (30 procent). Modellerna anpassades till träningsdata och utvärderades därefter på testdata med hjälp av RMSE (*Root Mean Squared Error*), MAE (*Mean Absolute Error*) samt genom visuell granskning av observerade och predikterade värden. För att möjliggöra en direkt jämförelse mellan modellansatsernas förklaringsgrad beräknades även ett prediktivt R^2 på testdata för samtliga modeller enligt ekvation 1.

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}{\sum_{i=1}^{n}(y_i - \bar{y}_i)^2} \quad (1)$$

Där y_i är observerad fukthalt för observation i, $\hat{y}_i$ är modellens predikterade fukthalt och $\bar{y}$ är medelvärdet av observerad fukthalt i testdatasetet.

För LME- och GAM-modellerna bedömdes variablernas betydelse utifrån skattade effekter och statistisk signifikans, medan variabelbetydelsen i Random Forest baserades på modellens interna mått på variabelbetydelse. Samtliga utvärderingar genomfördes separat för både regionala och lokala modeller.

Resultat

Korrelationsanalysen visade att vädervariabler beräknade för 30 dagar före åtgärd, generellt uppvisade starkare samband med fukthalten än motsvarande variabler beräknade över kortare tidsperioder (Tabell A1, Bilaga A). Undantag var temperatur vid skotning och luftfuktighet före avverkning. Vindvariablerna uppvisade genomgående svaga samband med fukthalten, medan väderförhållanden vid avverkning generellt hade lägre korrelation än väderförhållanden vid skotning och inmätning. *LagringTotalt* uppvisade inget signifikant linjärt samband med fukthalten och ersattes därför av *LagringHygge* och *LagringVälta* i den fortsatta modelleringen.

Modell 1: Linear mixed-effect model

Efter iterativ modellförenkling bestod den slutliga LME-modellen av 16 signifikanta fasta förklarande variabler, samt *Virkesordernummer* som slumpmässig gruppeffekt. Den slutliga modellen inkluderade geografisk position, lagringstid i välta, säsongsvariabler samt vädervariabler kopplade till avverkning, skotning och inmätning, se exakt modellansats i Bilaga B. Residualerna var i huvudsak normalfördelade utan tydliga systematiska mönster, varför någon transformation av responsvariabeln inte bedömdes nödvändig (Figur B1, Bilaga B). Samtliga VIF-värden understeg även 2, vilket indikerar låg multikollinearitet mellan de förklarande variablerna i modellen.

Den regionala modellen uppnådde ett marginalt R^2 på 0,331 och ett villkorat R^2 på 0,594. Den justerade intraklasskorrelationen (ICC) uppgick till 0,394, vilket indikerar ett tydligt beroende mellan observationer inom samma virkesorder och därmed styrker valet att inkludera virkesordernummer som slumpmässig effekt i modellen. Modellmåtten för de lokala modellerna redovisas i Tabell 3. Förklaringsgraden varierade mellan områdena, där område 2 uppnådde högst marginalt och villkorat R^2 (0,483 respektive 0,700).

Bland de fasta effekterna uppvisade temperatur och nederbörd före inmätning, temperatur vid skotning samt sommarrelaterade vädervariabler de starkaste statistiska sambanden med fukthalten. Sambanden mellan fukthalt och dag på året (DOY) var generellt svaga i LME-modellen, där avverknings- och inmätningsdag uppvisade relativt låga t-värden, medan skotningsdag exkluderades under modellförenklingen.

Tabell 3: Modellmått för den regionala och de lokala LME-modellerna. Marginalt R^2 beskriver den variation som förklaras av de fasta effekterna, medan villkorat R^2 inkluderar både fasta och slumpmässiga gruppeffekter.

Modell: LME	Marignalt R^2	Villkorat R^2	Justerat ICC
Regional	0,331	0,594	0,394
Lokal, Område 1	0,293	0,558	0,375
Lokal, Område 2	0,483	0,700	0,419
Lokal, Område 3	0,433	0,634	0,353
Lokal, Område 4	0,398	0,579	0,301
Lokal, Område 5	0,287	0,554	0,391

Modell 2: Generalized additive model

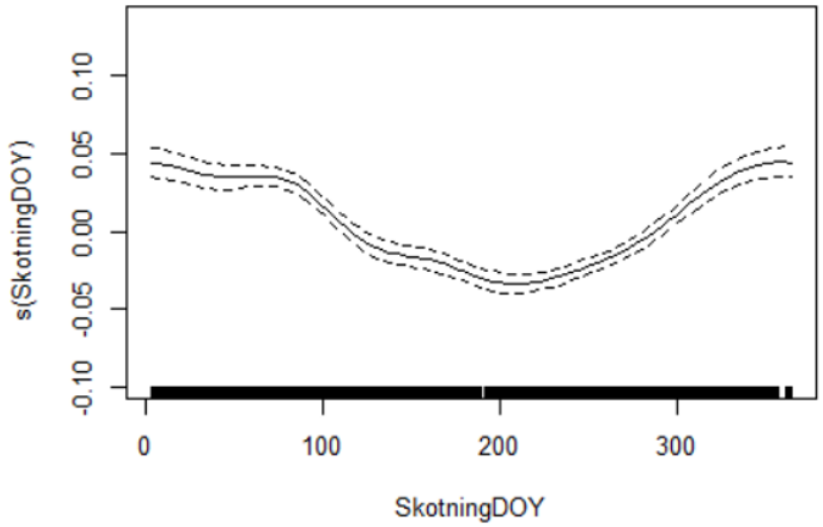
Efter iterativ modellförenkling bestod den slutliga GAM-modellen av sex linjära termer, sju spline-termer samt *Virkesordernummer* som slumpmässig effekt. Modellen inkluderade geografisk position, lagringstid i välta, säsongsvariabler samt olika vädervariabler kopplade till avverkning, skotning och inmätning, se fullständig modellansats i Bilaga C. Den geografiska positionen modellerades med en tvådimensionell spline baserad på SWEREF99-koordinater. Samtliga inkluderade parametriska och icke-linjära termer i den regionala modellen var statistiskt signifikanta. Residualerna var i huvudsak normalfördelade utan tydliga systematiska mönster, vilket indikerade att modellens antaganden var rimligt uppfyllda och ingen transformation av data var nödvändig (Figur C1, Bilaga C).

Den regionala modellen förklarade 39,7 procent av variationen i observerad fukthalt. För de lokala modellerna varierade förklaringsgraden mellan områdena, där förklarad devians uppgick till mellan 35,2 procent och 59,6 procent (Tabell 4). De cykliska splinefunktionerna för avverknings-, skotnings- och inmätningsdag (DOY) visade att tidpunkten för dessa aktiviteter hade en tydlig icke-linjär påverkan på fukthalten och tydliga säsongsmönster, medan den tvådimensionella splinen för geografisk position visade på komplexa rumsliga mönster. Samtliga splinefunktioner ses i Bilaga C och den skattade icke-linjära funktionen för Skotningsdag i Figur 8 nedan. När modellens övriga variabler hölls konstanta skattades fukthalten till cirka 6–8 procentenheter lägre för grot som skotades under sommaren än för grot som skotades under vinterhalvåret.

Bland de linjära termerna uppvisade nederbörd under de 30 dagarna före inmätning (RegnInmat30d), sommarregn (SommarRegn) och temperatur under de 30 dagarna före inmätning (TempInmat30d) de starkaste sambanden med fukthalten.

Tabell 4: Justerat R^2 och förklarad devians (%) för den regionala GAM-modellen samt de lokala modellerna.

Modell: GAM	Justerad R^2	Förklarad devians
Regional	0,391	39,7 %
Lokal, Område 1	0,333	35,2 %
Lokal, Område 2	0,569	59,6 %
Lokal, Område 3	0,501	51,6 %
Lokal, Område 4	0,488	51,9 %
Lokal, Område 5	0,342	35,5 %



Figur 8. Partiell effekt av skotningsdag (DOY) på fukthalt i den regionala GAM-modellen. Figuren visar den skattade splinefunktionen, vilken beskriver det icke-linjära sambandet mellan tidpunkt för skotning och fukthalt efter att övriga variabler i modellen beaktats. Värden över noll innebär att skotningstidpunkten bidrar till en högre predikterad fukthalt än modellens genomsnittsnivå, medan värden under noll innebär en lägre predikterad fukthalt. Effekten är centrerad kring noll, vilket innebär att y-axeln inte visar faktisk fukthalt utan skotningsdagens relativa bidrag till den predikterade fukthalten. De streckade linjerna anger 95 % konfidensintervall.

Modell 3: Random Forest

Random Forest-modellen utvecklades med samtliga variabler som valts ut i den inledande variabelscreeningen, utan ytterligare variabelselektion. Modellen inkluderade geografisk position, lagringstider, säsongsvariabler samt vädervariabler kopplade till avverkning, skotning och inmätning. Den regionala random forest-modellen uppnådde en förklarad variation på 50,7 procent. Variabelbetydelsen, beräknad som procentuell ökning av medelkvadratfelet (%IncMSE) respektive ökning i nodrenhet (IncNodePurity), visade att sommarnederbörd, temperatur vid inmätning, relativ luftfuktighet vid skotning och lagringstid i välta tillhörde de mest betydelsefulla prediktorerna i modellen (Bilaga D). Den förklarade variationen varierade mellan de lokala modellerna, med värden mellan 44,4 procent och 59,2 procent beroende på område (Tabell 5).

Tabell 5. Förklarad variation (%) för regionala Random Forest-modellen samt de lokala modellerna.

Modell: Random Forest	Förklarad varians
Regional	50,7 %
Lokal, Område 1	44,4 %
Lokal, Område 2	59,2 %
Lokal, Område 3	54,8 %
Lokal, Område 4	47,6 %
Lokal, Område 5	45,1 %

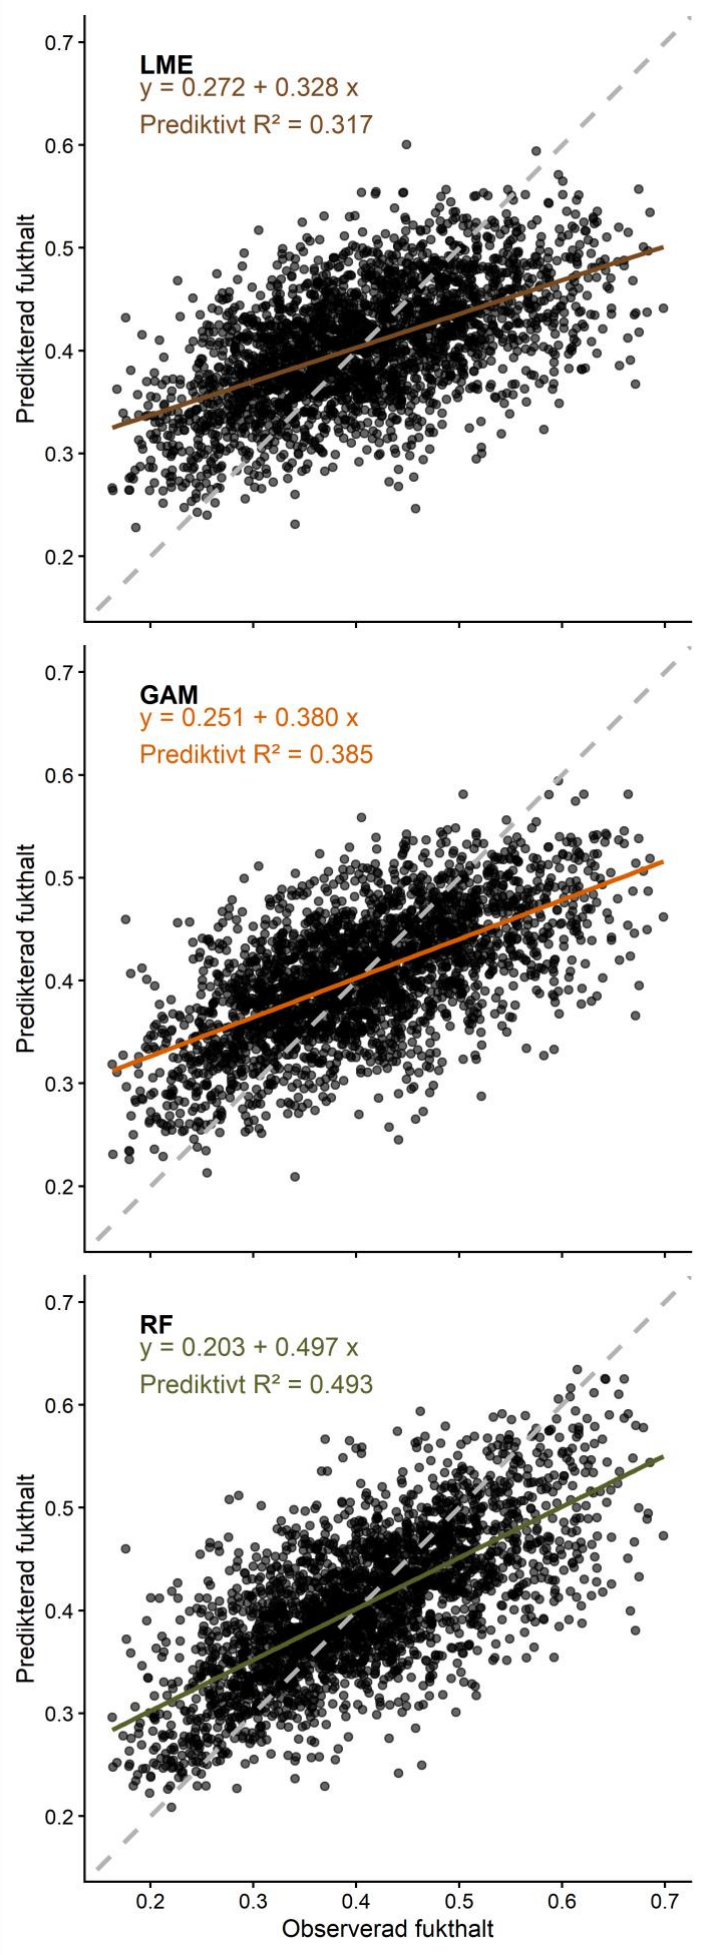
Jämförelse av modellerna

För att möjliggöra en direkt jämförelse mellan modellerna utvärderades deras prediktionsförmåga på oberoende testdata. Random forest-modellen uppvisade högst prediktivt R^2 (0,493) samt lägst RMSE (0,072) och MAE (0,055), följt av GAM-modellen och därefter LME-modellen (Tabell 6).

Jämförelsen mellan observerade och predikterade fukthalter visade att samtliga modeller drar sig mot medelvärdet och tenderade att underskatta höga fukthalter och överskatta låga fukthalter (Figur 9). Detta återspeglades i regressionslinjernas lutningar, vilka var lägst för LME-modellen (0,328) och högst för random forest-modellen (0,497). Random forest-modellen återgav därmed den observerade variationen i fukthalt bättre än de övriga modellerna.

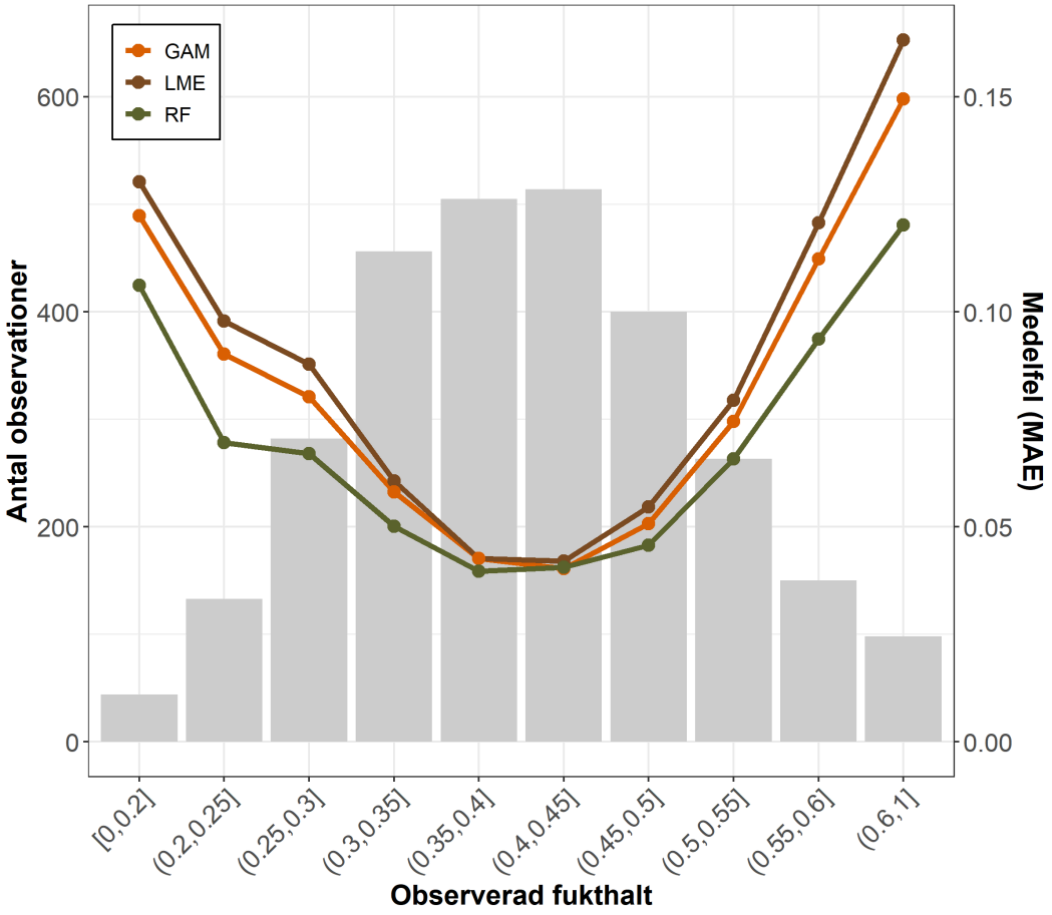
Tabell 6: Prediktivt R^2, RMSE och MAE för de regionala LME-, GAM- och random forest-modellerna beräknade på oberoende testdata. Högre prediktivt R^2 samt lägre RMSE- och MAE-värden indikerar bättre prediktionsförmåga.

Regional Modell	Prediktivt R^2	RSME	MAE
LME	0,318	0,083	0,067
GAM	0,385	0,079	0,063
RF	0,493	0,072	0,055



Figur 9. Jämförelse mellan observerad och predikterad fukthalt för LME-, GAM- och Random Forest-modellerna. Varje punkt representerar en observation. Den streckade grå linjen visar perfekt överensstämmelse mellan observerade och predikterade värden (1:1-linjen), medan de färgade linjerna visar linjär skattning av samband mellan observerad och predikterad fukthalt. För varje modell redovisas regressionslinjens ekvation samt modellens prediktiva R^2.

MAE varierade mellan olika intervall av observerad fukthalt (Figur 10). Samtliga modeller uppvisade lägst prediktionsfel (knappt 5 procentenheter) vid fukthalter omkring 35–45 procent, vilket sammanföll med både materialets genomsnittliga fukthalt och de intervall som innehöll flest observationer. Prediktionsfelen ökade successivt mot både lägre och högre fukthaltsvärden. För extremvärden, fukthalter under 20 procent respektive över 60 procent, översteg medelabsolutfelet 10 procentenheter för samtliga modelltyper. Random Forest-modellen uppvisade genomgående lägst medelabsolutfel över hela fukthalts intervallet, men skillnaderna mellan modellerna var relativt små vid fukthalter omkring 35–45 procent.



Figur 10. Medelabsolutfel (MAE) för LME-, GAM- och Random Forest-modellerna inom olika fukthaltsintervall. Linjerna avser MAE (höger y-axel) medan staplarna visar antalet observationer inom respektive fukthaltsintervall (vänster y-axel).

Diskussion

Syftet med studien var att undersöka i vilken utsträckning grotens fukthalt kan förklaras och predikteras med hjälp av tillgängliga data så som: koordinater, lagringstider, datum och meteorologiska data. Resultaten visar att samtliga modeller kunde fånga betydande delar av variationen i fukthalt, men att prediktionen fortfarande är förknippad med relativt stora osäkerheter. Random Forest uppvisade bäst prediktionsförmåga med ett prediktivt R^2 på 0,493, följt av GAM (0,385) och LME (0,318) (Figur 9). Detta innebär att den bästa modellen reducerade den oförklarade variationen med ungefär 50 procent, jämfört med en modell som enbart predikterade medelfukthalt.

Trots att modellerna uppvisade relativt måttliga förklaringsgrader var medelfelen på prediktionerna inom det vanligaste fukthaltsintervallet relativt låga. För fukthalter mellan 30 och 50 procent, där majoriteten av observationerna återfanns, uppgick Random Forest-modellens medelabsolutfel till omkring 5 procentenheter. Inom detta intervall understeg prediktionsfelet ±5 procentenheter i cirka två tredjedelar av fallen. Samtidigt visade samtliga modeller tydliga svårigheter att prediktera extremvärden. För fukthalter under 20 procent respektive över 60 procent översteg medelabsolutfelen 10 procent-enheter för samtliga modelltyper. Detta kan delvis förklaras av att dessa intervall innehöll relativt få observationer, men resultaten tyder även på att viktiga lokala förklaringsfaktorer sannolikt saknas i datamaterialet.

Att modellerna systematiskt drog prediktionerna mot medelvärdet och underskattade höga respektive överskattade låga fukthalter indikerar att en betydande del av variationen orsakas av faktorer som inte fångas av de inkluderade variablerna. Detta stöds även av resultaten från LME-modellen, där det justerade ICC-värdet uppgick till 0,394, vilket innebär att nästan 40 procent av den kvarvarande variationen kunde hänföras till skillnader mellan virkesordrar. Detta tyder på att orderspecifika, lokala faktorer har stor betydelse för den slutliga fukthalten. Exempel på sådana faktorer kan vara vältans orientering, exponering för sol och vind, markfuktighet, träslagsblandning, vältstorlek samt om vältan varit täckt eller inte. Flera av dessa faktorer är kända för att påverka uttorkningen (Erlandsson 2008, Johannesson m.fl. 2023) men saknas i tillgängliga registerdata i denna studie och normalt sett även i den operativa verksamheten.

Trots begränsningarna i tillgängliga data ger resultaten viss kunskap om vilka processer som påverkar grotens fukthalt. I samtliga modeller identifierades väderförhållanden 30 dagar före inmätning och skotning som viktiga förklaringsvariabler, särskilt nederbörd och temperatur. Även sommarrelaterade vädervariabler återkom som betydelsefulla faktorer. Att både nederbörd före inmätning och sommarregn identifierades som viktiga variabler tyder på att fukthalten påverkas av processer på flera tidsskalor. Nederbörd nära inmätning speglar sannolikt kortsiktiga effekter av aktuellt väder, medan sommarregn beskriver långsiktiga effekter kopplade till torkning och lagringsförhållanden.

GAM-modellen visade även tydligt att flera av dessa samband är icke-linjära. Medan dag på året uppvisade svaga samband i LME-modellen gav GAM-modellen tydliga säsongsmönster, exempelvis skotningsdag (Figur 8). Efter hänsyn till övriga variabler skattades fukthalten för grot som skotades under sommaren till cirka 6–8 procentenheter lägre än för grot som skotades under vinterhalvåret. Detta tyder på att säsongseffekterna är reella, men att de inte kan beskrivas på ett tydligt sätt med stöd i enkla linjära samband. Samma trend har också rapporterats av Erlandsson (2008) och Parlow (2012). Av operativa och praktiska skäl utförs grotskotningen året runt (Figur 5), men denna

studie visar att tidpunkten koncentreras under perioden maj–oktober, så att materialet hinner skotas till en välta och täckas före hösten, då återfuktningen vanligtvis tar fart.

Resultaten från de lokala modellerna indikerar också att geografiska skillnader har betydelse. För både LME och GAM ökade modellernas förklaringsgrad tydligt i vissa områden, framför allt i område 2 (Uppland, Södermanland) där de lokala modellerna uppnådde de högsta förklaringsgraderna. Random Forest uppvisade däremot mer jämn prestanda mellan områdena. Detta kan tyda på att den mer flexibla modellstrukturen bättre kan hantera regionala variationer utan behov av områdesspecifika anpassningar. Samtidigt presterade samtliga modellansatser bättre i områdena längs östkusten, där medelfukthalten även var lägre, än i inlandsområdena, vilket väcker frågor kring vilka regionala faktorer som påverkar modellernas prestanda. Det hade varit särskilt intressant att inkludera data från västkusten i framtida studier. Historiskt uppvisar dessa områden generellt högre fukthalter till följd av ett fuktigare klimat, men det är i dagsläget oklart om sådana förhållanden också skulle vara lättare eller svårare att modellera.

Osäkerhetskällor i indata

Väderdata hämtades från ett rutnät med en relativt grov upplösning på cirka 11 × 11 km, vilket innebär att lokala vädervariationer och mikroklimat inte fångas fullt ut. Det finns även osäkerheter kring koordinaternas kvalitet, vilket kan innebära att väderdata hämtas från fel geografisk position. Koordinaterna i studien ska betraktas som en ungefärlig plats och indikerar inte den exakta positionen för vältan eller vältornas placering vid bilväg.

Lagringsvariabler som används i modellerna (koordinater och väderdata) beskriver inte nödvändigtvis de exakta lagringsförhållandena för varje enskild välta. En virkesorder består av en eller flera leveranser, som i sin tur består av material från en eller flera vältor som kan ha liknande men aldrig exakt samma lagringsförhållanden.

Fukthaltsmätningarna (responsvariabel) förväntas även innehålla osäkerheter, främst kopplade till provtagningens representativitet snarare än till själva analysmetoden. Provtagningen behöver anpassas efter storleken och antal leveranser som ingår i virkesordern för att uppnå noggrannhetskav i regelverket (Biometria 2026). Om responsvariabeln påverkas av mätfel kan det försvaga sambandet med de förklarande variablerna och bli svårare för statistiska modeller att identifiera underliggande orsakssamband. Trots osäkerheten kring responsvariabel så ligger fukthalten till grund för betalningen och bör därför vara representativ och erhålla tillräcklig kvalitet för studiens syfte. I praktiken mäts cirka 75 procent av groten som förbrukas via Biometria (Parklund 2023), det vill säga Biometrias egen personal, auktoriserade mätande företag, industrins egen personal eller lastbilschaufförer, som utbildats inom ramen för Biometrias anvisningar och regelverk.

En del av modellernas begränsade förklarings- och prediktionsförmåga kan därför bero på datakvaliteten snarare än på valet av modellansats. Vid framtida satsningar på att vidareutveckla fukthaltsmodeller kan det därför vara mer värdefullt att förbättra mätmetoder och kvaliteten på indata än att enbart utveckla mer avancerade modelleringsmetoder. Detta innefattar bland annat att utöka mängden tillgängliga förklaringsvariabler samt att samla in fler observationer från underrepresenterade geografiska områden och fukthaltsintervall. Utvecklingen av nya, snabba och tillförlitliga metoder för fukthaltsmätning pågår (Hyll m.fl. 2023) och har potential att ge mer representativa mätningar av fukthalten, vilket kan bidra till att minska osäkerheterna i de fukthaltsdata som ligger till grund för modellutvecklingen.

Slutsatser

Sammantaget visar studien att grotens fukthalt är svår att prediktera. Variationen i fukthalt är komplex och påverkas av många faktorer som inte fångas upp i dagens datamaterial. Till skillnad från rundvirkesegenskaper (Hyll m.fl. 2024), som i hög grad bestäms vid avverkningen, förändras grotens fukthalt kontinuerligt under lagringen genom ett komplext samspel mellan väder, materialegenskaper och lokala lagrings-förhållanden. Trots dessa utmaningar visar fukthaltsmodellerna i denna studie att de kan ge betydligt bättre skattningar av fukthalten än att enbart utgå från historiska medelvärden. Studien visar därmed att ett datadrivet angreppssätt baserat på enkla och lättillgängliga variabler kan utgöra ett användbart komplement till mer processbaserade modeller och ge en grund för fortsatt utveckling av operativa beslutsstöd inom skogsbränslehanteringen. Den fortsatta utvecklingen av sådana modeller är dock beroende av representativa data av hög kvalitet för träning och utvärdering. Förbättrad kvalitet i referensdata genom säkrare fukthaltsbestämning, tillsammans med ett utökat datamaterial, bedöms därför vara viktiga förutsättningar för att ytterligare stärka modellernas robusthet och prediktionsförmåga.

Grot till ett värde av flera miljarder kronor lagras varje år runt om i landet. Åtgärder som skapar goda förutsättningar för uttorkning och vidare hantering av materialet (Johannesson m.fl. 2024), förbättrar dagens system för att prognostisera grotmängder (Fernandez-Lacruz m.fl. 2026) och möjliggör utveckling och tillämpning av fukthaltsmodeller (som i denna studie) bör därför betraktas som viktiga. Sådana åtgärder kan öka värdeskapandet för både leverantörer och förbrukare samt stärka försörjningstryggheten.

Referenser

Acuna, M., Antila, P., Sikanen, L., Prinz, R., & Asikainen, A. 2012. Predicting and Controlling Moisture Content to Optimise Forest Biomass Logistics. Croat. J. for. Eng. 33(2012)2.

Andersson, L. 2025. Grothantering i Sverige - skogsaktörers prioriteringar och strategier. Examensarbete 2025:17, Skogsmästarprogrammet, Sveriges lantbruksuniversitet (SLU), Skogsmästarskolan, Skinnskatteberg.

Biometria. 2026. Bestämning av torrhalt och energiinnehåll på skogsråvara. Nationella bestämmelser för virkesmätning 2026-04-01.

Copernicus Climate Change Service, Climate Data Store. 2020. E-OBS daily gridded meteorological data for Europe from 1950 to present derived from in-situ observations. Copernicus Climate Change Service (C3S) Climate Data Store (CDS). DOI: 10.24381/cds.151d3ec6 (Accessed on 10-06-2026)

Cornes, R., van der Schrier, G., van den Besselaar, E.J.M., Jones, P. 2018. An Ensemble Version of the E-OBS Temperature and Precipitation Datasets, J. Geophys. Res. Atmos., 123.

Energimyndigheten. 2025. Tillförsel av energi. https://www.energimyndigheten.se/energisystem-och-analys/sveriges-energisystem/hur-fungerar-energisystemet/tillforsel/ [2026-10-03]

Erber, G., Routa, J., Wilhelmsson, L., Raitila, J., Toiviainen, M., Riekkinen, J., & Sikanen, L. 2014. A prediction model prototype for estimating optimal storage duration and sorting. Working Papers of the Finnish Forest Research Institute, No. 297.

Eriksson, A., Westerblom, S., Hyll, K., Parklund, T., & Ene, L. 2025. Fukthalt och värde förändras under lagring. Skogforsk Kunskapsartikel Nr 2025-14. https://www.skogforsk.se/kunskapsbanken/kunskapsartiklar/2025/fukthalt-och-varde-forandras-under-lagring/ [2025-02-21]

Erlandsson, J., 2008. Fukthalt i GROT - påverkande faktorer. Examensarbeten 2008:20. Umeå: Sveriges lantbruksuniversitet (SLU), Institutionen för skogens ekologi och skötsel.

Fernandez-Lacruz, R. & Bergström, D. 2017. Windrowing and fuel chip quality of residual forest biomasses in northern Sweden. International Journal of Forest Engineering. Volume: 28, Number: 3, pp 186-197.

Fernandez Lacruz, R., Silverbratt, M., Westerblom, S. & Hannrup, B. 2026. Hur mycket grot finns egentligen på hygget, och var ligger den? Kunskapsartikel Nr 2026–45, Skogforsk. https://www.skogforsk.se/kunskapsbanken/kunskapsartiklar/2026/hur-mycket-grot-finns-egentligen-pa-hygget-och-var-ligger-den/ [2026-06-25]

Hyll, K., Iwarsson Wide, M., Ottosson, P. & Anderson, D. 2023. Snabb fukthaltsmätning av trädbränsle. Skogforsk Kunskapsartikel Nr 2023–48. https://www.skogforsk.se/kunskapsbanken/kunskapsartiklar/2023/snabb-fukthaltsmatning-av-tradbransle/ [2026-10-13]

Hyll, K., Möller, J., Eriksson, I., Arlinger, J., Ohlström, A., Lindgren, N. & Wilhelmsson, L. 2024. Så kan skördardata ge information om fukthalt och flisegenskaper. Kunskapsartikel Skogforsk Nr 2024–37. https://www.skogforsk.se/kunskapsbanken/kunskapsartiklar/2024/sa-kan-skordardata-ge-information-om-fukthalt-och-flisegenskaper/ [2026-10-12]

Johannesson T, Valund T, Eliasson L, Eriksson A, Anerud E, Fernandez-Lacruz R & Parklund T. 2023. Uttag av grot som skogsbränsle. SLU Skogsmästarskolans Rapportserie 2023:01. 75 s.

Lehtikangas, P. 1999. Lagringshandbok för trädbränslen. Uppsala: Inst. För virkeslära, Sveriges lantbruksuniversitet. ISBN 91-576-5564-2.

Lennartsson, T. 2022. Prognostisering av fukthalt i hyggesrester med användning av väderinformation. Examensarbete, Linnéuniversitetet, Institutionen för skogs- och träteknik.

Lindblad, J., Routa, J., Ruotsalainen, J., Kolström, M., Isokangas, A., Sikanen, L. 2018. Weather based moisture content modelling of harvesting residues in the stand. Silva Fennica vol. 52 no. 2 article id 7830. 16 p. https://doi.org/10.14214/sf.7830

Möller, J. J., Hannrup, B., Larsson, W., Barth, A. & Arlinger, J. 2009. Ett system för beräkning och geografisk visualisering av avverkade kvantiteter skogsbränsle baserat på skördardata. Arbetsrapport Nr 677–2009, Skogforsk.

Parklund, T. 2023. Fuktig eller torr – hur blir groten i år? Skogforsk Kunskapsartikel Nr 2023–17. https://www.skogforsk.se/kunskapsbanken/kunskapsartiklar/2023/fuktig-eller-torr---hur-blir-groten-i-ar/ [2023-03-24]

Parlow, H. 2012. Kvalitetsarbete i grotskotning (Examensarbete 2012:22). Skogsmästarprogrammet, Sveriges lantbruksuniversitet (SLU), Skogsmästarskolan, Skinnskatteberg.

R Core Team. 2026. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL https://www.R project.org/

Routa, J., Kolström, M., Ruotsalainen, J., & Sikanen, L. 2016. Validation of prediction models for estimating the moisture content of logging residues during storage. Biomass and Bioenergy, 94(85–93). https://doi.org/10.1016/j.biombioe.2016.08.019

Skogforsk. 2023a. Fakta Skogsbränsle [Faktablad]. Skogforsk. https://www.skogforsk.se/cd_20231116162027/contentassets/3cac6b78890d467bb033cac1bac7df28/faktasammanstallning-grot_20231025_press.pdf

Skogforsk. 2023b. Projektsida: Förbättrade grotprognoser för precisionsplanering. https://www.skogforsk.se/projekt/forbattrade-grotprognoser-for-precisionsplanering/

Skogforsk. 2026. WeCalc – Räkna på skogsbränsle. https://www.skogforsk.se/rad--stod/beslutsstod--verktyg/wecalc/ [2026-10-03]

Skogskunskap. 2024. Lagring av grot. https://www.skogskunskap.se/skota-skog/skorda-skogsbransle/grenar-och-toppar/lagring-av-grot/ [2026-10-14]

Skogskunskap. 2025. Grotens kvalitet och energiinnehåll. https://www.skogskunskap.se/skota-skog/skorda-skogsbransle/grenar-och-toppar/grotens-kvalitet-och-energiinnehall/ [2026-10-14]

Svenska institutet för standarder (SIS). 2024. SS-EN ISO 18134–2:2024. Fasta biobränslen – Bestämning av fukthalt – Torkning i ugn – Del 2: Total fukthalt – förenklad metod. Svenska institutet för standarder.

Thorngren, E. 2025. Optimera försörjningskedjan för GROT. Examensarbete 2025:11, Skogsmästarprogrammet, Sveriges lantbruksuniversitet (SLU), Skogsmästarskolan, Skinnskatteberg.

Wilhelmsson, L., Andersson, M., Bhuiyan, N., Persson, E., Jirjis, R., & Blom, T. 2015. Fukthalt med hjälp av väderdata. Skogforsk, Kunskapsartikel Nr 2015–95. https://www.skogforsk.se/kunskapsbanken/kunskapsartiklar/2015/fukthalt-med-hjalp-av-vaderdata/ [2025-08-11]

Bilagor

Bilaga A: Korrelationsanalys

Tabell A1. Linjära samband mellan studerade variabler och observerad fukthalt uttryckt som Pearsons korrelationskoefficient (cor). p_adj anger p-värden efter korrigering för multipla tester. Röd text anger samband som inte var statistiskt signifikanta efter korrigering för multipla tester (p_adj > 0,05). Orange text anger signifikanta men svaga samband (|cor| <0,10).

Variabel	cor	p_adj
SWEREF99_NS	0.002	8.741e-01
SWEREF99_EW	-0.183	6.784e-72
LagringTotalt	0.002	8.354e-01
LagringHygge	0.036	5.672e-04
LagringValta	-0.022	3.628e-02
RegnAvverkning30d	0.120	1.611e-31
RegnAvverkning7d	0.067	8.277e-11
RegnInmat30d	0.139	2.074e-41
RegnInmat7d	0.097	6.031e-21
RegnSkotning30d	0.123	4.210e-33
RegnSkotning7d	0.052	6.142e-07
TempAvverkning30d	0.146	8.858e-46
TempAvverkning7d	0.131	4.467e-37
TempInmat30d	-0.314	3.037e-214
TempInmat7d	-0.285	1.327e-175
TempSkotning30d	-0.223	1.279e-106
TempSkotning7d	-0.255	5.240e-140
RHAvverkning30d	0.011	3.062e-01
RHAvverkning7d	0.036	5.403e-04
RHInmat30d	0.191	1.138e-77
RHInmat7d	0.143	9.755e-44
RHSkotning30d	0.271	3.840e-158
RHSkotning7d	0.230	1.576e-113
VindAvverkning30d	-0.117	8.942e-30
VindAvverkning7d	-0.101	1.706e-22
VindInmat30d	0.051	8.155e-07
VindInmat7d	0.027	8.443e-03
VindSkotning30d	0.039	1.557e-04
VindSkotning7d	0.045	1.605e-05
SommarMedelTemp	-0.140	1.178e-39
SommarTempSum	-0.140	8.047e-40
SommarRegn	0.257	1.029e-133
InmatningDOY	-0.181	3.258e-70
SkotningDOY	0.047	7.200e-06
AvverkningDOY	0.117	8.942e-30

Bilaga B: Linear mixed-effect model

Slutlig modellansats:

```
Fukthalt ~ SWEREF99_EW + SWEREF99_NS + RegnSkotning30d + VindSkotning7d
    + TempSkotning7d + RHSkotning30d + RegnInmat30d + TempInmat30d +
    RHInmat30d + TempAvverkning30d + VindAvverkning30d + InmatningDOY +
    AvverkningDOY + LagringValta + SommarTempSum + SommarRegn +
    (1|VONUM)
```

Där `(1|VONUM)` anger ett random effekt för Virkesordernummer.

Parameterskattningar:

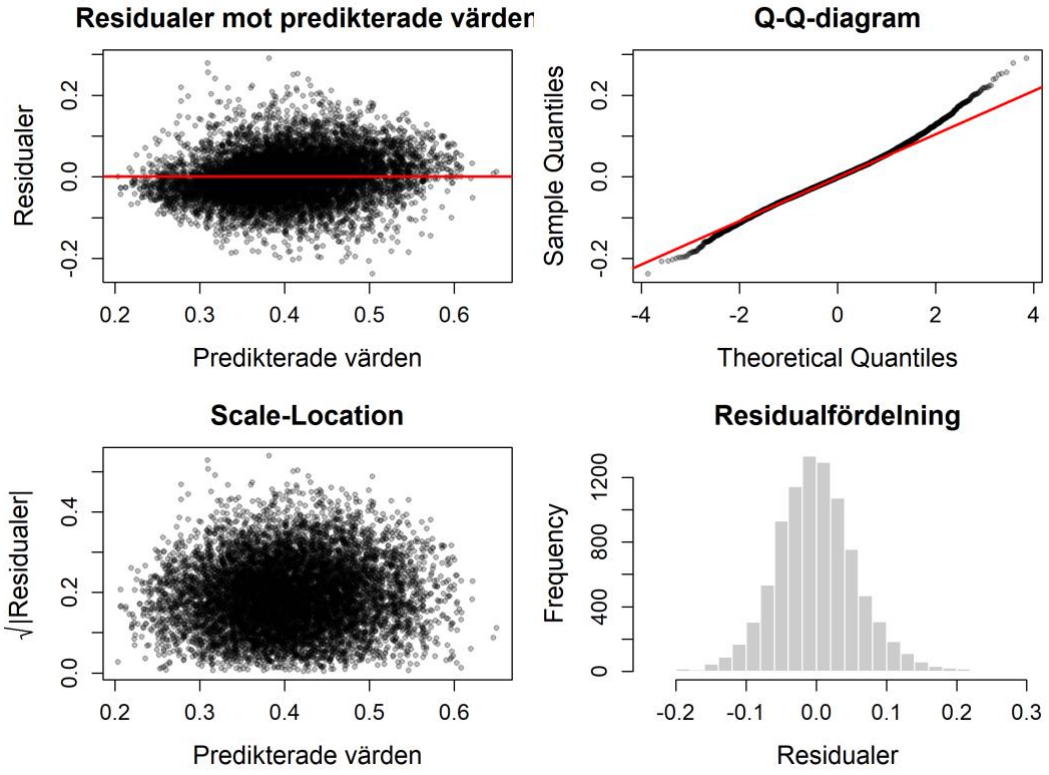
Tabell B1. Resultat från den linjära mixade modellen. Tabellen visar skattade fasta effekter (Koefficient), standardfel och p-värden för samtliga inkluderade variabler. Koefficienterna anger den genomsnittliga förändringen i modellens predikterade fukthalt per enhets förändring i respektive variabel. Variablerna representerar olika typer av mått och har olika skalor, vilket innebär att koefficienternas numeriska storlek inte bör användas för att jämföra variablernas relativa betydelse.

VARIABEL	KOEFFICIENT	STD. FEL	P-VÄRDE
SWEREF99_EW	-1,144E-07	2,572E-08	< 0,001
SWEREF99_NS	-4,422E-08	1,170E-08	< 0,001
RegnSkotning30d	0,001474	0,000410	< 0,001
VindSkotning7d	0,007337	0,002135	< 0,001
TempSkotning7d	-0,02987	0,002567	< 0,001
RHSkotning30d	0,001458	0,000173	< 0,001
RegnInmat30d	0,000399	0,000037	< 0,001
TempInmat30d	-0,005162	0,000263	< 0,001
RHInmat30d	0,000390	0,000161	0,0158
TempAvverkning30d	0,01917	0,002279	< 0,001
VindAvverkning30d	-0,01177	0,002808	< 0,001
InmatningDOY	-0,0000584	0,0000093	< 0,001
AvverkningDOY	0,0000456	0,0000135	< 0,001
LagringValta	-0,000135	0,000054	0,0126
SommarTempSum	-0,000191	0,000021	< 0,001
SommarRegn	0,000231	0,000018	< 0,001

Tabell B2. Varianskomponenter från den linjära mixade modellen. Tabellen redovisar skattad varians och standardavvikelse för den slumpmässiga interceptttermen (Virkesordernummer) och residualvariationen samt modellens intraklasskorrelation (ICC). Standardavvikelserna motsvarar cirka 5,2 procentenheters variation mellan Virkesordernummer och 6,5 procentenheters residualvariation i fukthalt. ICC visar att cirka 39 % av den totala variationen i fukthalt kan hänföras till skillnader mellan Virkesordernummer.

MODELLPARAMETER	VÄRDE
STD Intercept (Slumpeffekt)	0,052
Varians (Slumpeffekt)	0,00270
Residual STD	0,065
Residual varians	0,00416
ICC	0,394

Residualdiagnostik:



Figur B1. Residualdiagnostik för LME-modellen. Figuren visar residualer mot predikterade värden (övre vänster), ett Q-Q-diagram för residualerna (övre höger), ett Scale-Location-diagram (nedre vänster) samt ett histogram över residualfördelningen (nedre höger).

Bilaga C: Generalized additive model

Modellansats:

```
Fukthalt ~ s(SWEREF99_EW, SWEREF99_NS, k = 50) + s(RegnSkotning30d) +
    s(RHSkotning30d) + RegnInmat30d + TempInmat30d + RHInmat30d +
    VindSkotning7d + VindInmat30d + SommarRegn + s(LagringValta) +
    s(InmatningDOY, bs = "cc") + s(SkotningDOY, bs = "cc") +
    s(AvverkningDOY, bs = "cc") + s(VONUM, bs = "re")
```

Parameterskattningar:

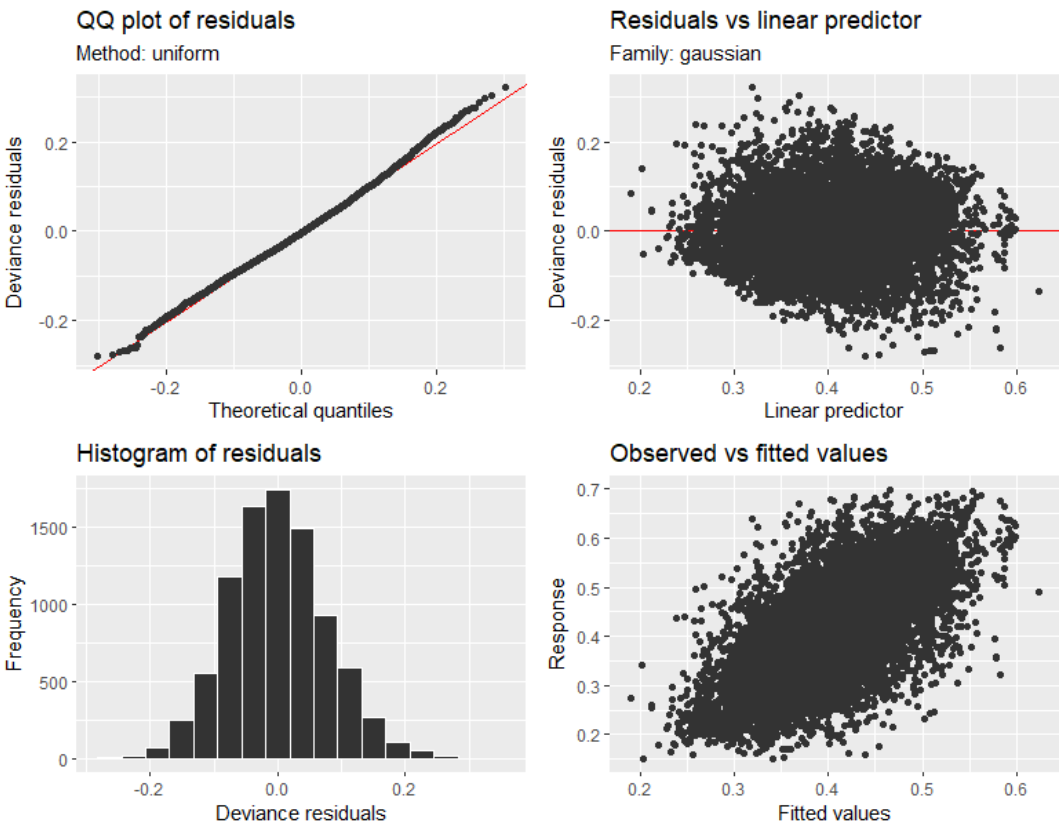
Tabell C1. Parametriska koefficienter för den generaliserade additiva modellen (GAM). Tabellen visar skattade linjära effekter, standardfel och p-värden för modellens parametriska termer. Koefficienterna anger den förväntade förändringen i predikterad fukthalt vid en enhets förändring i respektive variabel, givet att övriga modelltermer hålls konstanta. Eftersom variablerna mäts i olika enheter och på olika skalor är koefficienternas numeriska storlek inte direkt jämförbar mellan variabler.

Variabel	Koefficient	Standardfel	P-värde
RegnInmat30d	0,00045	0,00004	<0,001
TempInmat30d	-0,00390	0,00050	<0,001
RHInmat30d	0,00124	0,00024	<0,001
VindSkotning7d	0,00584	0,00161	<0,001
VindInmat30d	-0,00519	0,00252	0,039
SommarRegn	0,00020	0,00001	<0,001

Tabell C2. Resultat för de spline-termer som ingår i GAM. Tabellen visar uppskattat antal frihetsgrader (EDF), F-värde och p-värde för respektive term. EDF beskriver komplexiteten i det skattade sambandet mellan variabeln och fukthalten, där värden nära 1 motsvarar ungefär linjära samband och högre värden indikerar ökande grad av icke-linearitet. P-värdet avser ett test av om termen bidrar signifikant till modellen, medan F-värdet beskriver styrkan i denna effekt relativt modellens återstående variation.

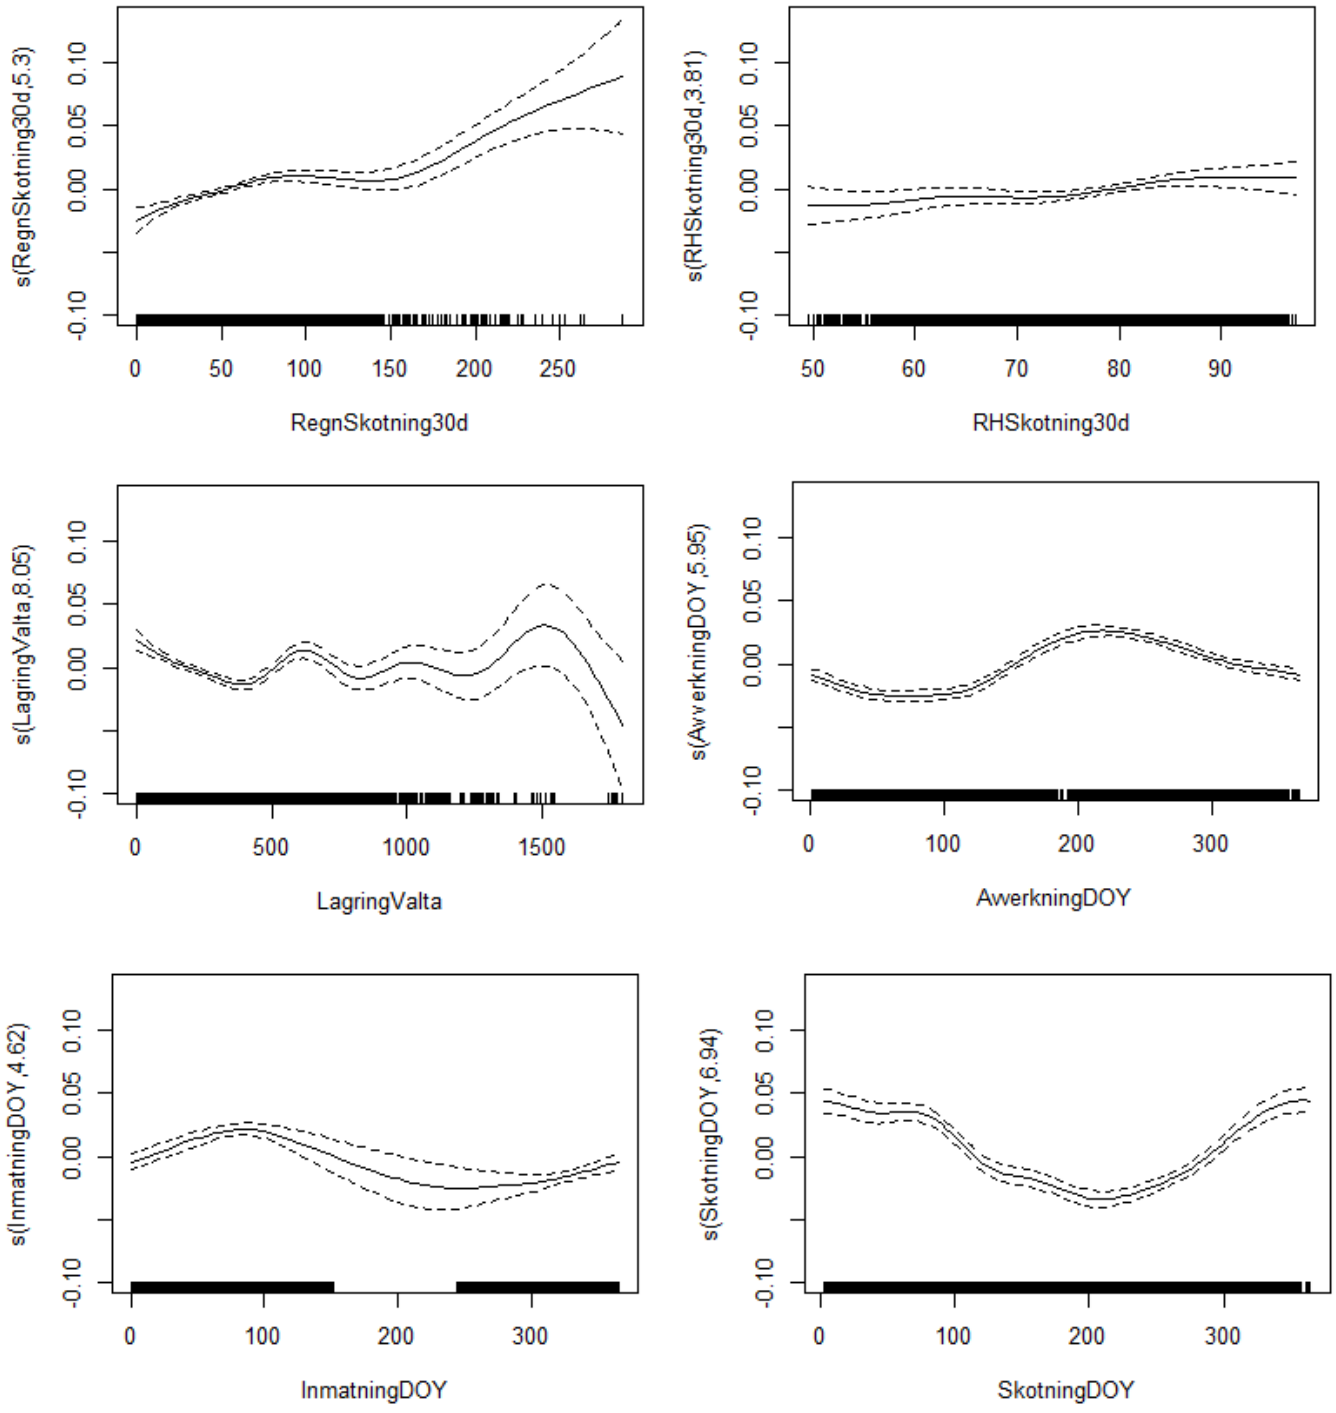
Smooth-term	EDF	F-värde	P-värde
s(SWEREF99_EW, SWEREF99_NS)	40,819	17,619	<0,001
s(RegnSkotning30d)	5,298	9,488	<0,001
s(RHSkotning30d)	3,815	1,471	0,003
s(LagringValta)	8,048	10,980	<0,001
s(InmatningDOY)	4,619	12,941	<0,001
s(SkotningDOY)	6,944	31,885	<0,001
s(AvverkningDOY)	5,950	52,679	<0,001
s(VONUM)	0,942	16,202	<0,001

Residualdiagnostik:

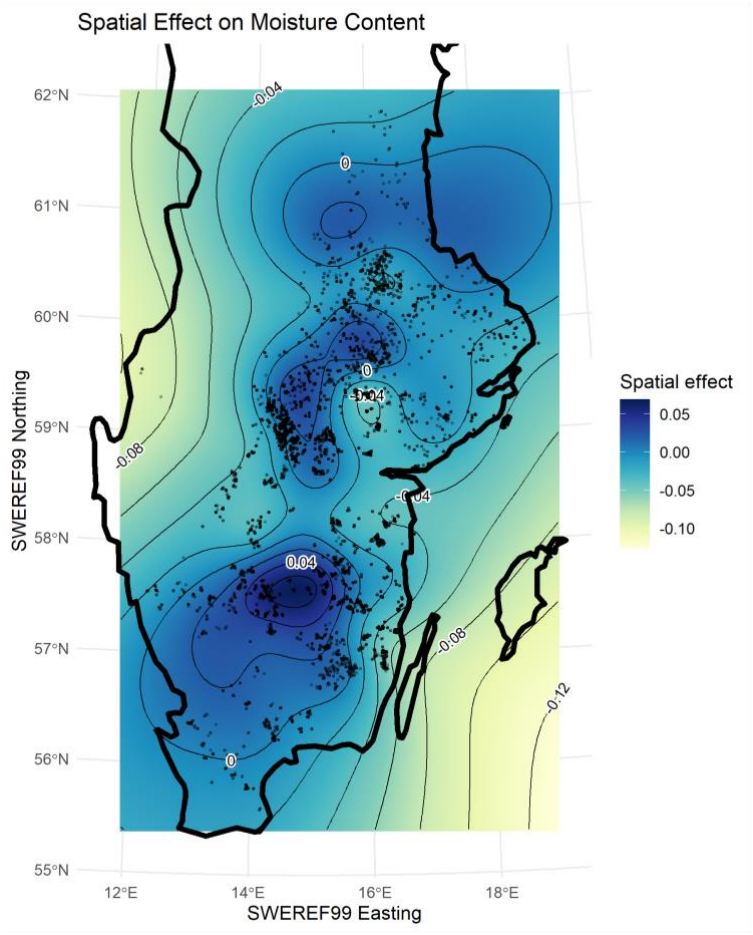


Figur C1. Residualdiagnostik för den generaliserade additiva modellen (GAM). Residualerna uppvisar i huvudsak god överensstämmelse med modellantagandena. QQ-diagrammet och histogrammet indikerar en approximativt normalfördelad residualstruktur, medan residualer mot linjär prediktor inte visar några tydliga systematiska avvikelser. Sambandet mellan observerade och predikterade värden tyder på att modellen fångar en betydande del av variationen i fukthalt.

Samtliga smoothing-termer:



Figur C2. Skattade partiella effekter för modellens spline-termer i den generaliserade additiva modellen (GAM). Den heldragna linjen visar den skattade effekten av respektive variabel på fukthalten, efter att övriga variabler i modellen har beaktats. De streckade linjerna anger ungefärliga 95-procentiga konfidensintervall och markeringarna längs x-axeln visar fördelningen av observationer. Y-axeln visar respektive terms bidrag till modellens linjära prediktor, centrerat kring noll. Figuren illustrerar flera tydligt icke-linjära samband mellan de undersökta variablerna och fukthalten.



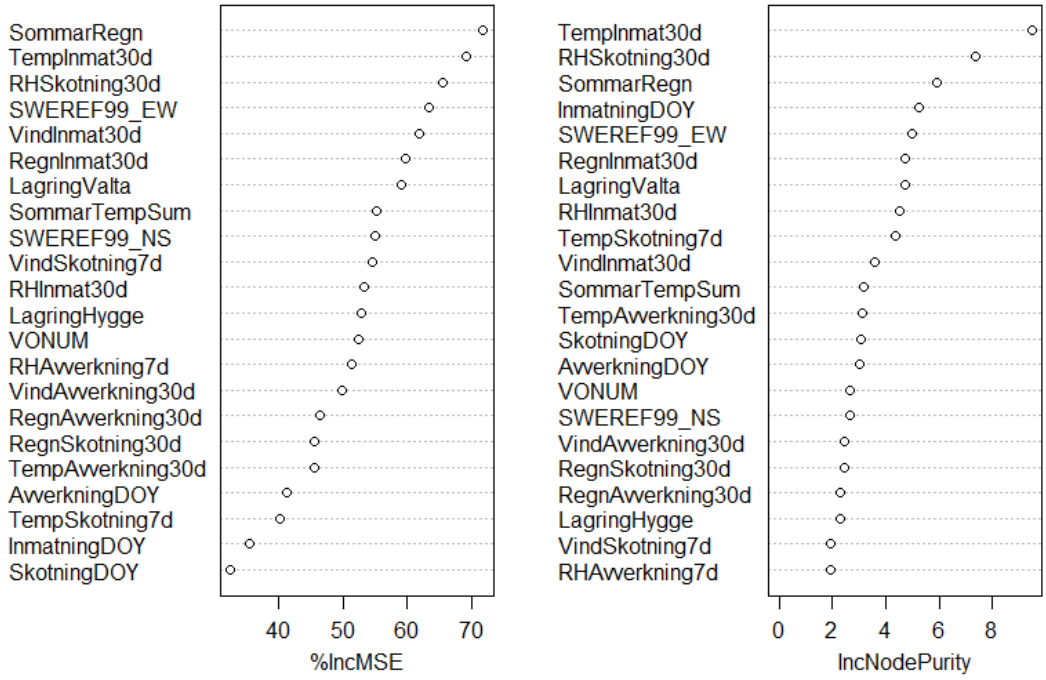
Figur C3. Skattad rumslig effekt från den tvådimensionella spline-termen för geografisk position (SWEREF99) i den generaliserade additiva modellen (GAM). Figuren visar den kvarvarande geografiska variationen i fukthalt efter att effekter av övriga förklaringsvariabler har beaktats. Mörkblå områden indikerar områden där modellen predikterar högre fukthalt än genomsnittet givet samma väder- och driftförhållanden, medan ljusgröna områden motsvarar negativa effekter och indikerar lägre predikterad fukthalt. De svarta punkterna anger observationernas geografiska position. Eftersom den rumsliga effekten skattas utifrån tillgängliga observationsdata är resultaten mest tillförlitliga i områden med hög datatäthet. Mönster i områden med begränsat observationsunderlag bör inte övertolkas.

Bilaga D: Random Forest

Slutligt modellansats:

```
Fukthalt ~ VONUM + SWEREF99_EW + SWEREF99_NS + RHAvverkning7d +
    RegnAvverkning30d + TempAvverkning30d + VindAvverkning30d +
    RegnSkotning30d + TempSkotning7d + RHSkotning30d + VindSkotning7d +
    RegnInmat30d + TempInmat30d + RHInmat30d + VindInmat30d +
    LagringValta + LagringHygge + SommarTempSum + SommarRegn +
    InmatningDOY + SkotningDOY + AvverkningDOY
```

Variabelbetydelse i modellen:



Figur D1. Variabelbetydelse i Random Forest-modellen beräknad med måtten %IncMSE och IncNodePurity. %IncMSE visar hur mycket modellens prediktionsfel ökar när informationen från en variabel slumpas bort och kan tolkas som ett mått på variabelns betydelse för modellens prediktionsförmåga. IncNodePurity beskriver variabelns bidrag till att minska residualvariansen genom trädens uppdelningar. Högre värden indikerar större betydelse för modellens prediktioner.