

Drönarinventering av vildsvinsskador på gröda

Inventering av gräsmark (betes- och
slåttervall) och vete i fyra ÄFO:n
i södra Sverige, 2024

Petter Kjellander, Yrsa Kleijkers,
Arvid Norström, Johan Månsson,
Florent Rumiano

RAPPORT 7203 | NOVEMBER 2025



Drönarinventering av vildsvinsskador på gröda

Inventering av gräsmark (betes- och slåttervall)
och vete i fyra ÄFO:n i södra Sverige, 2024

av Petter Kjellander, Yrsa Kleijkers, Arvid Norström,
Johan Månsson och Florent Rumiano

Naturvårdsverket
Tel: 010-698 10 00
E-post: registrator@naturvardsverket.se
Postadress: Naturvårdsverket, SE-106 48 Stockholm
Internet: www.naturvardsverket.se

ISBN 978-91-620-7203-2
ISSN 0282-7298

© Naturvårdsverket 2025

Tryck: Arkitektkopia AB, Bromma 2025
Omslagsfoto: Anders Broby, Naturvårdsverket

Förord

Vildsvin är uppskattade av många för jakten och köttet de ger. Samtidigt orsakar de stora skador på lantbruket och det är viktigt att få en uppskattning av dessa skador. I Sverige har det saknats en standardiserad och kvalitetssäkrad metod för att mäta vildsvinsskador på grödor.

År 2022 fick Naturvårdsverket uppdraget att utveckla en sådan metod. En överenskommelse träffades med Sveriges Lantbruksuniversitet (SLU) som nu utvecklat en metod för att objektivt kunna mäta skador på gröda orsakade av såväl vildsvin som andra typer av skador.

Denna rapport beskriver hur metoden fungerar och kan användas. Den redovisar också resultat från skadeinventeringar på gräsmark och vete för 2024 i fyra olika älgförvaltningsområden. Rapporten lyfter utvecklingsbehov som finns för att metoden ska kunna införas i större skala.

I Naturvårdsverkets strategi för svensk viltförvaltning 2022–2029, Viltstrategin, anges tre huvudperspektiv: bevarande av viltarter, brukande av viltet som resurs och begränsning av skador orsakade av vilt. Viltförvaltningen ska bygga bästa tillgängliga kunskap. Den tekniska utvecklingen möjliggör objektiva mätningar som komplement till de självskattningar av skador som idag används. Naturvårdsverket bedömer att mätbara och objektiva fakta kan bidra till att minska konflikter och skador på grödor, öka livsmedelsproduktionen och samtidigt möjliggöra fortsatt brukande av viltet som resurs.

Rapporten är skriven av Petter Kjellander, Yrsa Kleijkers Arvid Norström, Johan Månsson och Florent Rumiano, samtliga verksamma vid Grimsö forskningsstation, Institutionen för Ekologi, SLU. Författarna ansvarar själva för innehåll, slutsatser och eventuella rekommendationer i rapporten. Anders Broby har fungerat som redaktör på Naturvårdsverket under processen. Arbetet har finansierats via Naturvårdsverkets anslag för åtgärder för värdefull natur.

Stockholm 26 september 2025

Fredrik Hannerz
Avdelningschef Naturavdelningen

Innehåll

Förord	3
Sammanfattning	5
Summary	6
Bakgrund	7
1. Inledning	8
2. Studieområden	10
2.1 Val av älgförvaltningsområden	10
3. Material och metod	11
3.1 Val av inventerade fält	11
3.2 Inventeringsmetod och analys	12
3.3 Skadeorsakernas rumsliga fördelning på fält- och regional nivå	13
3.4 Skattning av AI-metodens tillförlitlighet	16
4. Resultat	18
4.1 Gräsmark (betes- och slåttervall)	18
4.1.1 Förekomst av gräsmark	18
4.1.2 Skattning av skadornas storlek på fältnivå (gräsmark)	19
4.1.3 Utbredning av skador på ÄFO-nivå (gräsmark)	20
4.2 Vete	25
4.2.1 Förekomst av vetefält	25
4.2.2 Skadornas skattade storlek i vetefält-nivå	25
4.2.3 Utbredning av skador på ÄFO-nivå (vete)	27
4.3 Validerade skador och träningsdata	32
4.4 AI-modulens precision	33
4.5 Prognos för algoritmernas förbättrade prestanda	34
4.6 Tidsåtgång	36
4.6.1 Använd hårdvara för bildanalys och AI-klassificering	37
5. Diskussion	38
5.1 Begränsningar och rekommendationer	40
5.1.1 Fältdata	40
5.1.2 Modellutformning	41
5.1.3 Rekommendationer	41
6. Tack till	43
7. Referenser	44
Bilaga 1 – Algoritmers statistiska tillförlitlighet	45
Bilaga 2 – Fältnens rumsliga fördelning, ÄFO-nivå	46

Sammanfattning

Denna rapport presenterar resultatet av ett uppdrag från Naturvårdsverket till SLU att utveckla och testa en drönar- och AI-baserad metod för att mäta viltskador på jordbruksgrödor. Syftet var att ta fram en standardiserad, objektiv metod som kan användas för att övervaka skador över tid och ge ett tillförlitligt beslutsunderlag från gårdsnivå till regional skala, till såväl lantbrukare som viltförvaltare och myndigheter.

Under odlingssäsongen 2024 genomfördes en fullskalig fältinventering i fyra viltrika älgförvaltningsområden (ÄFO) i fyra olika län i södra Sverige – Blekinge, Jönköping, Södermanland och Örebro. Både gräsmark (betes- och slåttervall) och vete ingick i studien. Målet var att pröva metodens genomförbarhet i större skala och samtidigt utvärdera dess precision, repeterbarhet och arbetsinsats. Datainsamlingen gjordes med hjälp av drönare utrustade med multispektrala sensorer. Bildmaterialet bestående av validerade skador användes därefter för att träna en AI-modul att särskilja skador av olika ursprung.

Resultaten visar att metoden fungerar väl för att identifiera och kvantifiera viltskador över stora arealer. Den genomsnittliga skadegraden för de fyra ÄFO:na sammantaget uppmättes till 17 % för både gräsmark och vete, med en bästa träffsäkerhet i AI-klassificeringen (i Örebro län) på 76 % respektive 89 %, för respektive gröda. Baserat på samtliga fyra områden var den bästa modellens träffsäkerhet dock något lägre (71 % i gräsmark och 85 % på vete), vilket tyder på viss heterogenitet i data mellan områden. De AI-skattade skadorna från vildsvin uppgick till 2 % i gräs och 5 % i vete, vilket är lägre än tidigare rapporterade bedömningar, och visar samtidigt hur objektiv teknik (till skillnad från mänskliga subjektiva observationer och enkätstudier) potentiellt kan komma att komplettera eller i vissa fall ersätta manuella metoder.

Genom studien identifierades också flera förbättringsområden, bland annat behovet av mer träningsdata för att öka modellernas tillförlitlighet och svårigheter att klassificera vissa skadetyper. Trots detta visar resultaten att tekniken redan nu kan tillämpas med relativt hög effektivitet. Totalt krävdes cirka 60 arbetsdagar från inventering till färdig analys av 100 fält med en medelstorlek på ca 3,5 ha (i denna studie), varav flygtiden är ca 6 dagar. Detta är en förbättring jämfört med våra tidigare tester och var möjligt genom att flyga på högre höjd (120 m) och en förenklad bildanalys. Med ytterligare automatisering och bättre datorresurser kan denna tidsåtgång minska betydligt i framtiden.

Sammantaget visar studien att en drönarbaserad, AI-stödd metod har stor potential att bli ett praktiskt verktyg för storskalig och upprepad viltskadeinventering av gröda, och kan därmed ge ett robust kunskapsunderlag för framtida beslut inom både lantbruket och viltförvaltningen.

Summary

This report presents the results of a commission from the Swedish Environmental Protection Agency (Naturvårdsverket) to the Swedish University of Agricultural Sciences (SLU) to develop and test a drone- and AI-based method for assessing wildlife damage to agricultural crops. The aim was to produce a standardized, objective method that can be used to monitor damage over time and provide a reliable basis for decision-making at scales ranging from individual farms to regional levels, supporting farmers, wildlife managers, and authorities.

During the 2024 growing season, a full-scale field survey was carried out in four wildlife management areas (ÄFOs) with high game densities across four counties in southern Sweden – Blekinge, Jönköping, Södermanland, and Örebro. The study included both grasslands (pasture and ley) and wheat fields. The objective was to test the feasibility of the method at a larger scale while also evaluating its accuracy, repeatability, and labor requirements. Data collection was conducted using drones equipped with multispectral sensors. The imagery, including validated damage observations, was then used to train an AI module to distinguish between different types of damage.

The results show that the method performs well in identifying and quantifying wildlife damage across large areas. The average damage level based on all four areas (ÄFOs) was measured at 17 % for both grasslands and wheat, with the highest AI classification accuracies (in Örebro county) of 76 % and 89 %, respectively. Based on all areas the overall accuracy was slightly lower (71 % in grassland and 85 % in wheat), suggesting some sort of heterogeneity in the data collection between areas. AI-estimated damage caused by wild boar amounted to 2 % in grassland and 5 % in wheat, which is lower than previously reported estimates and demonstrates how objective technology (as opposed to human observations) can complement or replace manual methods.

The study also identified several areas for improvement, including the need for more training data to increase model reliability and the difficulty of classifying certain types of damage. Nevertheless, the results indicate that the technology can already be applied with relatively high efficiency. A total of approximately 60 working days were required from survey to final analysis of 100 fields with an average size of about 3.5 hectares (in this study), of which flight operations accounted for around 6 days. This is an improvement compared to our earlier tests and was made possible by flying at a higher altitude (120 m) and using a simplified image analysis workflow. With further automation and improved computing resources, this time requirement could be significantly reduced in the future.

Overall, the study demonstrates that a drone-based, AI-assisted method holds great potential to become a practical tool for large-scale and repeated wildlife damage surveys in crops, thereby providing a robust knowledge base for future decisions in both agriculture and wildlife management.

Bakgrund

I denna rapport redovisas resultatet av en skadeinventering utvecklad för drönare och bildtolkning med hjälp av AI. Metoden är ett resultat av ett uppdrags- och utvecklingsarbete och redovisar resultaten av metodens tillämpning från fyra inventeringar i fyra olika län och på två olika grödor, gräsmark (betes- och slåttervall) och vete.

Naturvårdsverket gav SLU i uppdrag (2022-03-23) att utveckla och kvalitetssäkra en metod för att mäta viltskador på jordbruksmark. Uppdraget var att utveckla och *ge förslag på hur en standardiserad inventeringsmetod för att uppskatta skador på gröda*. Uppdragets slutrapport levererades till Naturvårdsverket 2024-10-09 (Kjellander et al. 2024; doi: 10.54612/a.2fjbv2ivoo). Den fortsatta utvecklingen av metodens AI-modul, samt validering, är grundligt beskriven i (Kleijkers et al. 2025 <https://doi.org/10.54612/a.176cfqd5in>).

Slutrapporten innefattade inte den sista delen av uppdraget där den utvecklade metodiken skulle testas mer storskaligt, utan redovisas separat i denna rapport. Under uppdragets sista fältperiod, odlingssäsongen 2024, genomfördes en fullskalig skadeinventering av gräsmark och vete i fyra olika älgförvaltningsområden (ÄFO) i södra Sverige. Målet med uppdragets slutfas var att implementera den tidigare utvecklade inventeringsmetoden och mäta skadornas storlek över större områden, samtidigt som metodens aktuella precision, arbetsinsats m.m. dokumenteras.

1. Inledning

Viltstammarnas utveckling ska vägas mot andra samhällsintressen. En central fråga är de ekonomiska konsekvenserna av viltskador på jordbruksgrödor i förhållande till viltets ekosystemtjänster och andra biologiska värden. Såväl jordbruks- som viltförvaltningen behöver underlag som gör det möjligt att fatta beslut om t.ex. ersättningar i vissa fall, förändrat jakttryck eller andra förebyggande åtgärder. Ofta saknas dock standardiserad och kvalitetssäkrad information om skadornas omfattning.

I Bergvall et al. (2022) redovisas tidigare försök till inventeringsmetoder, med fokus på deras upprepbarhet och tidsåtgång. Genomgången visar att det hittills saknats en metod som på ett objektivt och på större skala (län, älgförvaltningsområde (ÄFO) eller annan regional skala) kan kvantifiera viltskador – såväl för att beskriva nuläget som för att följa utvecklingen över tid. Lantbrukarnas Riksförbund anger i rapporten ”Toleransnivå för viltskador i jordbruket” (LRF 2022) att skadepåverkan i genomsnitt bör understiga 2–4 % av förväntad skörd för att anses vara acceptabel. Samma rapport pekar på att det saknas etablerade metoder för att mäta dessa skador tillförlitligt.

Behovet av en tids- och kostnadseffektiv storskalig inventeringsmetod är därmed stort, både för att ge en rättvisande bild av problemets omfattning och för att möjliggöra utvärdering av olika förvaltningsåtgärders effekt. Målbilden är således att utveckla en objektiv metod som kan skatta förlorad skörd orsakad av vilt, särskilt vildsvin, d.v.s. en metod som inte bygger på individuella personers bedömningar. Metoden behöver vara standardiserad, d.v.s. jämförbar mellan olika områden och mellan år, samt användbar från fältnivå upp till nationell nivå. Genom en sådan metod blir det möjligt att följa skadornas utveckling över tid och därigenom också utvärdera effekterna av förändringar i viltförvaltning och jordbrukets skadeförebyggande åtgärder.

Sedan LRF:s rapport (2022) har utvecklingen inom artificiell intelligens (AI), särskilt inom datorseende och avancerad bildanalys, tagit stora kliv framåt. Det är idag fullt realistiskt att använda autonoma system baserade på AI för att tolka drönarbilder och därmed på ett effektivt sätt identifiera och klassificera viltskador.

I detta projekt har drönare förutom vanliga sensorer för synligt ljus (RGB) utrustats med s.k. multispektrala sensorer, (NIR: near-infrared), för att kunna fånga detaljerade bilder av grödans tillstånd. NIR-sensorn möjliggör en typ av vegetationsanalys som ger indikationer på förändringar i grödan t.ex. växtstress, avsaknad av biomassa eller skada – d.v.s. information som är svåra att upptäcka med blotta ögat. De insamlade bilderna av jordbruksmark analyseras med hjälp av s.k. konvolutionella neurala nätverk (CNN), en typ av djupinlärning som är särskilt lämpad för bildigenkänning. Modellerna har tränats på bilder med olika typer av kända skador, där fokus ligger på att kunna särskilja viltskador från andra skadeorsaker (t.ex. torka, stenar, vatten eller maskinskador). Med hjälp av AI kan bedömningarna automatiseras, vilket inte bara minskar tidsåtgång, utan även eliminerar den subjektivitet som ofta präglar manuella bedömningar.

Under odlingssäsongen 2024 genomfördes en pilotstudie i fyra län – Blekinge, Jönköping, Södermanland och Örebro – inom det mest viltrika älgförvaltningsområdet (ÄFO:t) i respektive län. I varje område inventerades slumpmässigt utvalda

fält med hjälp av drönartekniken. Skadedata har därefter skalats upp för att ge en en genomsnittlig skadegrad inom varje ÄFO.

Denna rapport syftar därmed till att:

1. Undersöka genomförbarheten av en drönbaserad skadeinventering i stor skala.
2. Bedöma precision, repeterbarhet och tidsåtgång för metoden, inklusive den AI-baserade bildtolkningen.
3. Identifiera förbättringsområden för framtida tillämpning och vidareutveckling.
4. Bidra med ett första objektiva kunskapsunderlag rörande vildsvinsskador till lantbrukare, viltförvaltare och myndigheter.

2. Studieområden


2.1 Val av älgförvaltningsområden

Sammanlagt fyra älgförvaltningsområden i fyra olika län (Jönköpings-, Örebro-Södermanlands- och Blekinge län) inventerades för skador i betes-/slåttervall och vete under perioden maj till augusti, 2024. Val av län baserades på dess geografiska spridning i några av landets mer viltrika områden. Målet var att på detta sätt fånga upp eventuell variation mellan olika naturtyper, väder och "årsmån" som de olika länen representerar. Dessutom fördelades områdena i en nord-sydlig klimatgradient, för att underlätta fältarbetet så att fältarbete kunde spridas ut över tid (tidigast i Blekinge och senast i Örebro). I varje län valdes det älgförvaltningsområde ut som redovisat högst vilttillgång (Figur 1). Vilttillgången baserades på en kombination av officiella avskjutningssiffror för dovhjort och vildsvin under jaktåren 2018–2022 i respektive ÄFO. De utvalda ÄFO:na i respektive län var: "ÄFO 1 Nordöst" (Jönköpings län), "ÄFO-sydöstra" (Örebro län), "ÄFO 1" (Södermanlands län) och "ÄFO-öst" (Blekinge län). ÄFO:nas storlek varierade och var minst i Blekinge (106 336 ha) och störst i Södermanland (308 644 ha). På grund av förekommande flygrestriktionszoner innebar det att den verkliga inventerade arealen minskade avsevärt (ca 25 %) i vissa ÄFO:n. Efter att flygrestriktionszonerna borträknats var den totala och verkliga inventerade arealen för de fyra länen sammantaget 682 750 ha och målet var att inventera 100 fält per gröda och ÄFO d.v.s. totalt 800 fält (400 gräsfält samt 400 vetefält, Tabell 1).

3. Material och metod

3.1 Val av inventerade fält

Ett slumpmässigt urval av fält valdes ut för inventering bland samtliga jordbruksblock med vete och gräsmarker (betes- och slåttervall), som registrerats i Jordbruksverkets blockdatabas i maj, 2024, inom respektive ÄFO. Jordbruksverkets databas är dock komplett först i slutet av odlingssäsongen, varför vissa blocks (fortsättningsvis fält) gröddor endast var preliminärt registrerade vid tidpunkten för vårt urval (ca 10 %). Respektive ÄFO delades in i 10 delområden baserat på förekomsten av respektive gröda (Bilaga 2). Detta gjordes för att underlätta fältarbetet, så att körsträckan mellan fälten kunde minimeras. Inom varje delområde slumpades sedan 15 fält ut för inventering där de 10 första fält som vid besöket uppfyllde våra krav (med korrekt målgröda), inventerades. Skälet till att vissa fält föll bort var att det inte gick att komma i kontakt med den registrerade brukaren eller att den i blockdatabasen preliminärt registrerade grödan var felaktig, vilket kunde upptäckas först vid fältbesöket. Samtliga fält oavsett storlek ingick i randomiseringen. De i blockdatabasen registrerade brukarna kontaktades per telefon innan inventeringen och endast någon enstaka avböjde vårt fältbesök.



Figur 1. De inventerade ÄFO:nas geografiska placering i respektive län, till vänster. Till höger ett exempel från Jönköpings län (ÄFO 1 Nordöst) och de 10 delområdena där 10 randomiserade fält med vete eller gräsmark inventerades. Cirkeln i områdets sydöstra hörn markerar en flygförbudszon som inte ingick i inventeringen. För övriga ÄFO:n se Bilaga 2.

3.2 Inventeringsmetod och analys

Själva drönarinventeringen genomfördes enligt beskrivning i slutrapport ”*En standardiserad inventeringsmetod för att uppskatta skador på gröda – Med fokus på vilt och vildsvinsskador*” (Kjellander et al. 2024. <https://doi.org/10.54612/a.2fjbv2ivoo>). Den huvudsakliga förändringen från metoden som beskrivs i Kjellander et al. (2024) var i korthet att flyghöjden ökats från 40 m till 120 m – d.v.s. tillåten maxhöjd för denna typ av flygning. Detta får till följd att bildupplösningen på marken försämrats från 4 x 4 cm till 8 x 8 cm, per pixel. Dessutom uteslöts momentet med s.k. 3d flygning, som användes för att registrera höjdskillnader i grödan. Eventuella konsekvenser av dessa två förändringar beskrivs i 5.1.3.


Fälтарbetet, d.v.s. markpersonalens insamling av s.k. träningsdata för AI-metoden begränsades till vartannat fält och genomfördes vid samma tillfälle som drönarinventeringen. För träningsdata koordinatsätts varje enskild skada och skadeorsaken identifieras och registreras. Sammanlagt 12 olika skadeklasser kunde anges under fälтарbetet, men på grund av att vissa av dessa var mycket ovanliga begränsades analysfasen till de sex vanligaste skadeklasserna: torskador (Torka), körsador och sprutspår (Maskin), vattenrelaterade skador (Vatten), samtliga hjortdjursrelaterade skador, i de inventerade områdena var detta huvudsakligen dovhjortsskador (Hjort), stenar och synliga hållar (Sten) samt vildsvinsrelaterade skador (Vildsvin). Viltskadorna omfattade därmed såväl bök-, åt-, och trampskador. De viktigaste skadeklasser som utgick var räv, sork/mullvad, grävling, liggsäd, så-mista, samt ”annat” d.v.s. övriga skador (avlägg för avverkning, ensilagebalar m.m.). Dessa skadeklassers sammanlagda areal och förekomst var dock så begränsad att det bedömdes rimligt att utesluta dessa i detta skede. Det bör dock noteras att det i skadeklassen ”annat” också ingick skador som var allt för diffusa för att med säkerhet kunna hänföras till någon av de definierade skadeklasserna, något som sannolikt var ett misstag (se 5.1.1).

Sammanlagt användes fyra principiellt olika AI-metoder under maskininlärningsprocessen för att kartlägga, träna och identifiera de olika skadeklasserna. Först används två olika metoder ”Random Forest” (RF) och ”Support Vector Machine” (SVM). Dessa används för att automatiskt skilja skadad från oskadad gröda samt för att rumsligt avgränsa skadan på fältet. Därefter, för att definiera skadeorsak används en maskininlärningsmodul, eller CNN (Convolutional Neural Network/ konvolutionellt neuralt nätverk). Via ett sådant s.k. datorbaserat ”neuralt nätverk” är CNN särskilt bra på att analysera bilder och visuella mönster. Här användes antingen en s.k. objektbaserad träningsmetod respektive en pixelbaserad träningsmetod. Detta i kombination med en metod som antingen delar upp bilden i 30 x 30 pixel stora rutor (grid) eller behandlar hela bilden samtidigt (no-grid). Kortfattat handlar detta om olika sätt för algoritmen att träna på bilder med olika typer av validerade skador (Kleijkers et al. 2025). Något förenklat har vi därefter utvärderat metodens tillförlitlighet och den kan därför beskrivas som utvärderad på nivån från en mycket hög upplösning av enskilda pixel (8 x 8 cm) till avgränsade ”skadepolygoner”, och olika varianter där emellan. Detta genererar sammanlagt åtta olika skattningar av skadornas ursprung och storlek på varje enskilt fält, baserat på samma bild (ortomosaik). Vi testade denna ”mångfald” av träningsmetoder eftersom det saknades tidigare forskning och rekommendationer kring vilken upplösning eller vilket angreppssätt som bäst kunde definiera skadeorsaken

och uppskatta skadans storlek. I denna rapport redovisas endast den metod och det resultat som generellt framstod som bäst under nuvarande förhållande och baserat på den mängd träningsdata som projektet genererat. I Kleijkers et al. (2025) redovisas resultaten från samtliga metoder ända ned på fältnivå. Här, i denna rapport beskrivs skadornas storlek däremot enbart som medelvärden för den genomsnittliga skadans storlek, baserad på alla inventerade fält i ÄFO:t.

3.3 Skadeorsakernas rumsliga fördelning på fält- och regional nivå

Skadornas rumsliga utbredning beräknas på huvudsakligen två nivåer – dels på lokal (fält) nivå och dels på regional (ÄFO) nivå. För den enskilda brukaren och jakträttsinnehavaren är sannolikt båda nivåerna av intresse medan den övergripande förvaltningen är mer betjänt av information om skadeläget på den regionala nivån. Med metodens högsta upplösning kan de sex skadeorsakernas rumsliga fördelning inom ett fält redovisas med en upplösning om 8 x 8 cm. Den bild som genereras av fältet och dess skador kan sedan redovisas på en mängd olika vis. Antingen som samtliga sex skadeklassers enskilda utbredning på fältet, enbart vildsvinsskadornas utbredning, eller som andel skadad areal per m² (Figur 2A och B).



Figur 2A. Bilderna visar ett verkligt exempel på visualisering av en svårt skadad betesmark (1,6 ha) i Örebro län. Överst visas fältets utseende innan skadorna analyserats av AI-modulen, en s.k. ortomosaik. Nederst visas samma bild med de AI-definierade skadornas fördelning och skadegrad (procent skadat per m²). Den vita fläcken indikerar en berghäll. Data insamlat våren 2023.



Figur 2B. Samma fält som i Figur 2A. Överst exemplifieras: samtliga AI-definierade skadors utbredning (oavsett orsak, totalt 0,33 ha) på fältet och nederst skadorna uppdelade på två skadeklasser; vildsvinsskador (0,3 ha – motsvarande ca 19 % skadegrad) respektive övriga skador (sammanslagning av hjort, torka, vatten, sten och maskinskadorna). Fältets totala skadegrad var över 20 %.

De AI-definierade skadorna på fältnivå ligger till grund för skattningen av den totala skadegraden inom hela ÄFO:t. Stickprovsförfarandet och resultaten som genereras på varje enskilt fält är därför avgörande för att beskriva skadorna för ett större område på ett rättvisande sätt. I denna rapport har vi av såväl GDPR-skäl som av utrymmesskäl valt att inte redovisa skadornas utbredning på enskilda fält (ca 800 fält), utan endast skadornas interpolerade och relativa utbredning per km² inom respektive ÄFO. Skadorna visualiseras som extrapolerade värden mellan 0–1 per km², inom respektive ÄFO (Figur 3a–d samt Figur 4a–d). Där 0 indikerar att ett (eller flera) fält inom en km² är helt oskadat och 1 avser ett (eller flera) fält inom en km² som har ÄFO:ts mest omfattande skador. Därefter visualiseras skadorna omfattning på icke inventerade fält via s.k. interpolation, baserat på avstånd. Det betyder att om avstånden mellan de inventerade fälten (t.ex. ett skadat och ett oskadat) är långt, kommer de ”gissade” skadornas storlek i området emellan och som inte inventerats att visualiseras som gradvis avtagande skador från det skadade till det oskadade fältet. På samma sätt kan områden utan jordbruksmark framstå som potentiellt skadedrabbade, enbart på grund av att omkringliggande jordbruksmark har skador. Visualiseringsmetoden betyder också att även i relativt blygsamt skadade områden, kommer det område som är värst skadat inom ÄFO:t att framstå som allvarligt skadat, i jämförelse med övriga inventerade områden.

3.4 Skattning av AI-metodens tillförlitlighet

I Kleijkers et al. (2025) används sammanlagt sex olika sätt att beskriva en bildigenkänningsalgoritms kvalité och de benämns oftast på engelska (här med ett försök till svenska översättningar); ”Confusion Matris” (förväxlingsmatris), ”Korrekthet” (noggrannhet), ”Kappa” (samstämmighet justerad för slumpen), ”Precision” (träffsäkerhet), ”Recall” (känslighet) och ”F1-score” (se samtliga definitioner i Bilaga 1). Varje sätt eller mått fokuserar på specifika aspekter av hur väl AI-algoritmen presterar (t.ex. i detta fall hur ofta den klassar skadeorsak rätt). De olika sätten kan även vara olika lämpliga för olika situationer. I vissa situationer är *precision* viktigast t.ex. när falska positiva resultat är kritiska som vid sjukdomsdiagnostik, där ett falskt positivt resultat kan orsaka onödig oro eller onödig behandling. I andra fall är *recall* viktigast t.ex. när falska negativa resultat är oacceptabla, som vid brandsensorer, där det är viktigare att upptäcka alla bränder (även om vissa falsklarm kan inträffa). Ofta sammanfattas dessa mått som ett *F1-värde*, som balanserar *precision* och *recall*, vilket är viktigt när båda behöver beaktas samtidigt.

Korrekthet baseras på det totala antalet korrekt klassificerade bilder delat med det totala antalet bilder. Korrektheten varierar således mellan 0 och 1 och kan också uttryckas i procent. *Kappa* (Cohen’s Kappa) är ett statistiskt mått som används för att utvärdera överensstämmelsen mellan två ”bedömare” när de klassificerar samma uppsättning kända objekt. Skillnaden mot *Korrekthet* är att *Kappa* mäter hur AI-algoritmens klassificering presterar i förhållande till vad som kan förväntas av slumpen. De två ”bedömare” är antingen slumpen eller AI-algoritmen, i detta fall. *Kappa*-värdet varierar därför mellan –1 och +1 där 0 innebär att överensstämmelsen inte är bättre än slumpen, medan 1 innebär perfekt överensstämmelse. Negativa värden indikerar en överensstämmelse som är sämre än slumpen, vilket innebär att det finns ett allvarligt systematiskt fel i metoden. Ett värde runt +0,5 indikerar måttlig överensstämmelse med verkligheten. I denna studie har ett mål på > 0,9

bedömts som realistiskt att uppnå och det har även diskuterats i projektets referensgrupp (se Kjellander et al. 2024) som önskvärt för avnämarnas tillit till metoden.

Via ett upprepat förfarande där man varierar stickprovsstorleken kan också en varians beräknas för *Korrekthet* och *Kappa*. Slutligen används en redovisningsform av en s.k. *confusion matrix* som är ett verktyg för att enkelt redovisa, visualisera och för läsaren att själv kunna ”utvärdera” prestandan hos en klassificeringsmodell. Den ger en tydlig bild av hur väl modellen förutsäger olika klasser, genom att bryta ner resultaten i korrekta och felaktiga förutsägelser. Förutom respektive utfall i s.k. *confusion-matriser* redovisar vi i denna rapport huvudsakligen metodens *Korrekthet*, *Kappa* samt *F1-värde*.

4. Resultat

4.1 Gräsmark (betes- och slåttervall)

4.1.1 Förekomst av gräsmark

Det totala antalet fält med gräsmark i de fyra ÄFO:na var sammantaget 19 139 varav ca 2 % inventerades (Tabell 1). Totalt inventerades 383 fält på ett sådant sätt att resultaten kunde användas i denna rapport (Tabell 1). Skälen till att 17 fält inte togs med, varierade från misslyckade flygningar till avvikelser mellan fält som inventerats till fots (skadevaliderats) och som inventerats med drönare, vilket upptäcktes först i efterhand. Bortfallet p.g.a. misslyckade flygningar var i någon mån systematiskt, då det huvudsakligen var de allra minsta fälten som föll bort. Detta på grund av en oförutsedd effekt av drönarens programmering under de första flygningarna. Det gjorde att det inte var möjligt att återskapa ortomosaiker för de minsta fälten (huvudsakligen < 0,5 ha). När problemet väl uppdagades, ändrades flyginställningarna. Några av de allra största fälten (> 20 ha) föll också bort p.g.a. tidsbrist och dåliga ljusförhållanden i slutet av arbetsdagen. Vidare föll ytterligare fem gräsfält bort från analyserna, då dessa bestod av väldigt stora och diffusa tork- eller vattensskador. Dessa diffusa skadors ”utformning” innebar att det i efterhand var omöjligt att definiera och avgränsa, enbart baserat på ortomosaikerna.

Tabell 1. Deskriptiva data för det hos Jordbruksverket registrerade antalet fält med gräsmark (betes- och slåttervall) som ingick i inventeringen, fältens medelstorlek (ha) m.m., samt antalet fält, andelen (%), fältens medelstorlek (ha) m.m. inom fyra älgförvaltningsområden (ÄFO) i fyra olika län under sommaren 2024. Den rapporterade avskjutningen av vildsvin och dovhjort anges som medelavskjutningen för åren 2018–2022.

Län och ÄFO	Blekinge (ÄFO Öst)	Jönköping (ÄFO 1 Nordöst)	Södermanland (ÄFO 1)	Örebro (ÄFO Sydöstra)
Antal drönarinventerade fält	100	100	102	97
Antal använda fält för analys	92	72	95	96
Antal fält med träningsdata	43	46	52	46
ÄFO – Antal förekommande gräsfält	2 546	9 475	4 641	2 477
Andel inventerade fält inom ÄFO	4 %	1 %	2 %	4 %
Total inventerad areal (ha)	120	136	220	199
ÄFO – Total areal gräsfält (ha)	3 751	13 819	14 112	5 865
Andel inventerad area inom ÄFO	3 %	1 %	2 %	3 %
ÄFO – Medelfält (ha, ±SD)	1,5 (1,7)	1,5 (1,6)	3,0 (3,5)	2,4 (3,1)
ÄFO – Medianfält (ha, min-max)	1,0 (0,02–21)	0,9 (0,01–23)	1,9 (0,03–39)	1,4 (0,04–63)
Medelfält, inventerat (ha, ±SD)	1,3 (1,3)	1,5 (1,6)	3,0 (3,2)	2,1 (2,0)
Medianfält, inventerat (ha, min-max)	0,9 (0,1–6)	0,9 (0,2–8)	2,0 (0,2–20)	1,4 (0,2–10)
Dovhjort, avskjutning per 1000 ha	1	< 0,1	23	8
Vildsvin, avskjutning per 1000 ha	15	8	12	11

4.1.2 Skattning av skadornas storlek på fältnivå (gräsmark)

Baserat på samtliga inventerade fält varierade skadegradens omfattning mellan 6–42 % av respektive ÄFO:s totalt odlade areal gräsmark (Medel: 23 % skadegrad; Varians: $\pm 5,5$ %, Varians_{min-max}: 0,1 – 23 %). Skadorna var störst i Södermanland och minst i Jönköping (Tabell 2; Figur 3). Den enskilt mest omfattande skadeorsaken var vattenskadorna, som varierade (beroende på ÄFO) mellan 2–17 % av den odlade arealen och för genomsnittsfältet var vattenskadorna ca 8 % av arealen. Den genomsnittliga skadegraden orsakad av vildsvin varierade mellan 0,4–3 % beroende på ÄFO, i genomsnitt ca 2 % av arealen. AI-skattningarnas genomsnittliga tillförlitlighet på gräsmark (baserat på 4 ÄFO:n) är generellt låg i förhållande till vår målbild (Korrekthet: 72 %; Kappa: 0,62 samt F1: 69 %). I Örebro län, ÄFO-sydöstra, var tillförlitligheten högst (76 %) mätt som Korrekthet (Tabell 3).

Tabell 2. Totalt antal inventerade gräsmark (betes- och slåttervall), inventerad areal, AI-skattade skadors storlek, andel av den odlade arealen m.m., redovisad som medelvärden samt min-max baserat på 4 sydsvenska ÄFO:nr. Skadornas relativa storlek av den odlade arealen redovisas för 6 olika skadeorsaker (vildsvin, hjort, vatten, sten samt torka). Skillnaden mellan andelen skadad areal samt summan av de olika skadeklasserna består av klassen "Annat" (andra skador) och ingår inte i analysen av AI-modulernas tillförlitlighet. Data insamlad under odlingssäsongen 2024.

	Utfall	Min-Max
Totalt antal inventerade fält (antal)	355	72–96
Total inventerad areal (ha)	716	91–291
Totalt skattad skadad areal (ha)	119	6 – 67
Andel skadad areal	17 %	4–23 %
Medelvarians	6 %	0,1–12 %
Skadeorsak:		
Vildsvins skada	2 %	0,4–3 %
Hjortskadad	0 %	0–1 %
Torskadad	1 %	0–4 %
Maskinskadad	2 %	1–3 %
Sten	0 %	~0,1 %
Vattenskadad	6 %	2–11 %

Tabell 3. De genomsnittliga AI-skattade skadorna storlek i gräsmark (betes- och slåttervall) baserad på fyra sydsvenska ÄFO:n (ÄFO 1 Nordöst – Jönköpings län, ÄFO-sydöstra – Örebro län, ÄFO 1 – Södermanlands län och ÄFO-öst – Blekinge län) fördelade på 6 olika skadeklasser. Skillnaden mellan andelen skadad areal samt summan av de olika skadeklasserna består av klassen "Annat" (andra skador) och ingår inte i analysen av AI-modulens tillförlitlighet. AI-metodens tillförlitlighet i skattningen av de 6 skadeklasserna anges som "Korrekthet och "Kappa".


	Blekinge	Jönköping	Södermanland	Örebro
Antal fält	72	92	96	95
Inventerad areal (ha)	91	136	291	199
Skadad areal (ha)	12	15	56	35
Andel skadad areal	13 %	11 %	19 %	18 %
Varians (skada)	4 %	2 %	12 %	4 %
Skadeorsak:				
Vildsvin	2 %	1 %	3 %	3 %
Hjort	0 %	0 %	1 %	0 %
Torka	0 %	0 %	1 %	2 %
Maskin	2 %	1 %	1 %	1 %
Sten	0 %	0 %	0 %	0 %
Vatten	6 %	6 %	9 %	8 %
Tillförlitlighet:				
Korrekthet (% , varians)	74 (± 4 %)	67 (± 3 %)	70 (± 6 %)	76 (± 4 %)
Kappa (varians)	0,63 (± 0,07)	0,56 (± 0,07)	0,61 (± 0,08)	0,68 (± 0,08)

4.1.3 Utbredning av skador på ÄFO-nivå (gräsmark)


De AI-definierade skadornas rumsliga utbredning visualiseras på ÄFO-nivå och redovisas för respektive ÄFO (Figur 3a–d), var för sig. Notera att de visualiserade skadornas storlek *inte* kan jämföras mellan ÄFO:n eftersom de standardiserats för att variera mellan 0 och 1. Notera också att det generellt sett är en mycket liten andel av den totala arealen gräsmark som inventerats i respektive ÄFO. Dessutom, i ÄFO 1 i Sörmland kunde inte ett omfattande centralt område inventeras alls p.g.a. en omfattande flygförbudszon (Bilaga 2, Figur B3). Osäkerheten i de visualiserade kartorna är därför mycket stor och ska snarare mer ses som en framtida möjlighet till visualisering med stora förbättringsmöjligheter – än att tolkas bokstavligt, i detta skede.

Med hänsyn taget till ovan beskrivna svagheter att visuellt beskriva skadornas geografiska utbredning är det dock tydligt att vid en jämförelse mellan samtliga skadors utbredning och enbart vildsvinsskadornas utbredning i samma ÄFO, så framgår ett generellt visuellt mönster, även om det finns gott om undantag. Mönstret antyder att de områden som drabbats av skador, oavsett orsak, dessutom tycks drabbats hårdare av vildsvinsskador. Vilka slutsatser som kan dras av detta diskuteras senare.

Blekinge – ÄFO Öst, gräsmark




Blekinge – ÄFO Öst, gräsmark




Figur 3a. De AI-definierade och extrapolerade skadornas rumsliga utbredning i gräsmark (ÄFO Öst, Blekinge län. De sammanlagda skadorna utgör 13 % av den totalt odlade arealen gräsmark (överst) samt de vildsvinsdefinierade skadornas utbredning (nederst) utgör 2 % av den totalt odlade arealen gräsmark. Störst skador i det mörkaste gröna området noterades på ett 6 ha stort fält med totalt 18 % skadegrad och i det mörkaste röda området ett 5 ha stort fält med knappt 3 % vildsvinsskador. Svarta punkter indikerar de inventerade fälten och representerar 4 % av alla gräsfält samt utgör 3 % av den totala arealen odlad gräsmark. Övriga förklaringar till kartornas framtagande framgår i 3.1 samt 4.1.3. Data insamlat sommaren 2024.

Jönköpings län – ÄFO 1 Nordöst, gräsmark




Jönköpings län – ÄFO Öst, gräsmark




Figur 3b. De AI-definierade och extrapolerade skadornas rumsliga utbredning i gräsmark (ÄFO 1 Nordöst, Jönköpings län. De sammanlagda skadorna utgör 11 % av den totalt odlade arealen gräsmark (överst) samt de vildsvinsdefinierade skadornas utbredning (nederst) utgör 1 % av den totalt odlade arealen gräsmark. Störst skador i det mörkaste gröna området noterades på ett 6 ha stort fält med totalt 23 % skadegrad och i det mörkaste röda området på samma fält knappt 2 % vildsvinsskador. Svarta punkter indikerar de inventerade fälten och representerar 1 % av alla gräsfält samt utgör 1 % av den totala arealen odlad gräsmark. Övriga förklaringar till kartornas framtagande framgår i 3.1 samt 4.1.3. Data insamlat sommaren 2024.

Södermanland – ÄFO-1, gräsmark




Södermanland – ÄFO 1, gräsmark




Figur 3c. De AI-definierade och extrapolerade skadornas rumsliga utbredning i gräsmark (ÄFO 1, Södermanlands län). De sammanlagda skadorna utgör 19 % av den totalt odlade arealen gräsmark (överst) samt de vildsvinsdefinierade skadornas utbredning (nederst) utgör 3 % av den totalt odlade arealen gräsmark. Störst skador i det mörkaste gröna området noterades på ett 9 ha stort fält med totalt 16,5 % skadegrad och i det mörkaste röda området ett 11 ha stort fält med knappt 8 % vildsvinsskador. Svarta punkter indikerar de inventerade fälten och representerar 1 % av alla gräsfält samt utgör 1 % av den totala arealen odlad gräsmark. Övriga förklaringar till kartornas framtagande framgår i 3.1 samt 4.1.3. Den röda polygonen anger grovt flygförbudszonen, som inte kunde inventeras. Data insamlat sommaren 2024.

Örebro – ÄFO-sydöstra, gräsmark



Örebro – ÄFO-sydöstra, gräsmark



Figur 3d. De AI-definierade och extrapolerade skadornas rumsliga utbredning i gräsmark (ÄFO Sydöstra, Örebro län). De sammanlagda skadorna utgör 18 % av den totalt odlade arealen gräsmark (överst) samt de vildsvinsdefinierade skadornas utbredning (nederst) som utgör 3 % av den totalt odlade arealen gräsmark. Störst skador i det mörkaste gröna området noterades på ett 10 ha stort fält med totalt 17 % skadegrad och i det mörkaste röda området på samma fält knappt 4 % vildsvinsskador. Svarta punkter indikerar de inventerade fälten och representerar 4 % av alla gräsfält samt utgör 3 % av den totala arealen odlad gräsmark. Övriga förklaringar till kartornas framtagande framgår i 3.1 samt 4.1.3. Data insamlat sommaren 2024.

4.2 Vete

4.2.1 Förekomst av vetefält

Det totala antalet vetefält i de fyra ÄFO:na var sammantaget 2747 varav vi inventerade ca 11 % (Tabell 4). Totalt inventerades 298 vetefält på ett sådant sätt att resultaten kunde användas i denna rapport (Tabell 4). Skälen till bortfallet av så mycket som 102 fält, varierade från fält (vårvete) som inte nått full mognad, tids-/resursbrist (framförallt i Södermanland), misslyckade flygningar samt till mismatch mellan fält som inventerats till fots (skadevaliderats) och som inventerats med drönare (vilket upptäcktes först i efterhand). Bortfallet p.g.a. misslyckade flygningar var i någon mån systematiskt, då det var huvudsakligen de allra största fälten (>20 ha) som föll bort på grund av tidsbrist och sviktande ljusförhållanden i slutet av arbetsdagen.

Tabell 4. Deskriptiva data av det hos Jordbruksverket registrerade antalet vetefält (höst- och vårvete), dess medelstorlek (ha), samt antalet, andelen (%), medelstorlek (ha) inventerade vetefält inom fyra älgförvaltningsområden (ÄFO) i fyra olika län under sommaren 2024, samt rapporterad medelavskjutning per 1000 ha av vildsvin och dovhjort under åren 2018–2022.

Län och ÄFO	Blekinge (ÄFO Öst)	Jönköping (ÄFO 1 Nordöst)	Södermanland (ÄFO 1)	Örebro (ÄFO Sydöstra)
Antal drönnarinventerade fält	75	98	53	96
Antal använda fält för analys	74	93	35	96
Antal fält med träningsdata	41	47	14	40
ÄFO – Antal förekommande vetefält	277	390	1006	1074
Andel inventerade fält inom ÄFO	24 %	26 %	4 %	4 %
Totalt inventerad areal (ha)	277	330	303	311
ÄFO – Total areal vetefält (ha)	1170	1280	7985	6988
Andel inventerad areal inom ÄFO	27 %	25 %	5 %	9 %
ÄFO – Medelfält, ha ($\pm$ SD)	4,2 (3,6)	3,3 (3,9)	7,9 (8,6)	6,5 (7,2)
ÄFO – Medianfält, (ha, min-max)	3,3 (0,1–19)	2,2 (0,1–52)	5,4 (0,1–71)	4,2 (0,2–56)
Medelfält inventerat (ha $\pm$ SD)	3,7 (2,9)	3,5 (3,6)	6,3 (9,1)	3,2 (1,8)
Medianfält inventerat (ha, min-max)	3,0 (0,3–13)	2,3 (0,3–17)	3,8 (0,3–49)	2,9 (0,3–8)
Dovhjort, avskjutning per 1000 ha	17	7	12	8
Vildsvin, avskjutning per 1000 ha	1	1	28	17

4.2.2 Skadornas skattade storlek i vetefält-nivå

Baserat på samtliga ÄFO:n och 271 inventerade vetefält var skadegraden 17 % (Varians: $\pm 1,5$ %; Varians_{min-max}: 0,1 – 23 %). Beroende på ÄFO varierade skadegraden mellan 5–27 % av den totalt odlade arealen (Tabell 5 & 6). Konsekvent var skadorna störst i Jönköping och minst i Blekinge (Tabell 6; Figur 4). De enskilt vanligaste skadeorsakerna var vildsvinsskador och maskinskador som varierade mellan 2–10 % (beroende ÄFO). För genomsnittsfältet var skadegraden orsakad av maskiner < 5 % och ca 5 % för vildsvin. AI-skattningarnas tillförlitlighet på vete är generellt något låg i förhållande till vårt mål, men acceptabel och högre än på gräsmark (Korrekthet: 85 %; Kappa: 0,79 samt F1: 71 %) (Tabell 6). I Örebro län, ÄFO-sydöstra, var tillförlitligheten högst (89 %) mätt som Korrekthet (Tabell 6). Variationen i skadornas omfattning är stor mellan fält.

Tabell 5. Totalt antal inventerade vetefält (höst- och vårsådd), inventerad areal, AI-skattade skadors storlek, andel av den odlade arealen m.m., redovisad som medelvärden samt max-min baserat på 4 sydsvenska ÄFO:n. Skadornas relativa storlek av den odlade arealen redovisas för 6 olika skadeorsaker (vildsvin, hjort, vatten, sten samt torka). Skillnaden mellan andelen skadad areal samt summan av de olika skadeklasserna består av klassen "Annat" (andra skador) och ingår inte i analysen av AI-modulernas tillförlitlighet. Data insamlad under odlingssäsongen 2024.

	Utfall	Min-Max
Totalt antal fält	271	35–90
Total inventerad areal (ha)	1026	208–312
Skadad areal, medel (ha)	42	11–85
Andel skadad	17 %	5–27 %
Medelvarians	1 %	0,01–5 %
Skadeorsak:		
Vildsvin	5 %	1,8–9,5 %
Hjort	0 %	~0,1 %
Torka	1 %	0,1–2 %
Maskinskada	2 %	1–3 %
Sten	0 %	~0,1 %
Vatten	3 %	1–8 %

Tabell 6. De genomsnittliga AI-skattade skadorna storlek i vetefält (höst- och vår sådd) baserad på fyra sydsvenska ÄFO:n (ÄFO 1 Nordöst – Jönköpings län, ÄFO-sydöstra – Örebro län, ÄFO 1 – Södermanlands län och ÄFO-öst – Blekinge län) fördelade på 6 olika skadeklasser. Skillnaden mellan andelen skadad areal samt summan av de olika skadeklasserna består av klassen "Annat" (andra skador) och ingår inte i analysen av AI-modulens tillförlitlighet. AI-metodens tillförlitlighet i skattningen av de 6 skadeklasserna anges som "Korrekthet och "Kappa".


	Blekinge	Jönköping	Södermanland	Örebro
Antal fält	58	88	35	90
Inventerad areal	208	312	220	286
Skadad areal (ha)	22	66	43	39
Andel skadad, medel	11 %	21 %	20 %	14 %
Varians	1 %	1 %	1 %	3 %
Skadeorsak:				
Vildsvin	4 %	7 %	6 %	4 %
Hjort	0 %	0 %	0 %	0 %
Torka	1 %	1 %	1 %	1 %
Maskin	2 %	2 %	2 %	2 %
Sten	0 %	0 %	0 %	0 %
Vatten	2 %	4 %	5 %	2 %
Tillförlitlighet:				
Korrekthet (% , varians)	86 (±2 %)	82 (±5 %)	80 (±2 %)	89 (±2 %)
Kappa (varians)	0,81 (±0,04)	0,72 (±0,08)	0,70 (±0,04)	0,84 (±0,04)

4.2.3 Utbredning av skador på ÄFO-nivå (vete)


De AI-definierade skadornas rumsliga utbredning visualiseras för var och ett av de fyra ÄFO:na (Figur 4a–d). Notera att de visualiserade skadornas storlek *inte* kan jämföras mellan ÄFO:n eftersom de standardiserats för att variera mellan 0 och 1. Den inventerade arealen vete uppgick i vissa ÄFO:n endast till 5 % medan i andra nästan 30 % av den totala arealen. Precis som i fallet med gräsmarksinventeringen var det ett större område inom ÄFO 1 i Södermanland inte kunde inventeras p.g.a. en omfattande flygförbudszon (Bilaga 2). Osäkerheten i de visualiserade kartorna är stor även för vete och ska mer ses som en framtida möjlighet till visualisering – med stora förbättringsmöjligheter – än att tolkas bokstavligt, i detta skede.

Med hänsyn taget till ovan beskrivna svagheter att visuellt beskriva skadornas geografiska utbredning antyder ändå mönstren att de områden som drabbats av skador, oavsett orsak, dessutom tycks drabbas hårdare av vildsvinsskador. Vilka slutsatser som kan dras av detta diskuteras senare.

Blekinge – ÄFO Öst, vete




Blekinge – ÄFO Öst, vete




Figur 4a. De AI-definierade och extrapolerade skadornas rumsliga utbredning i vete (ÄFO Öst, Blekinge län). De sammanlagda skadorna utgör 11 % av den totalt odlade arealen vete (överst) samt de vildsvinsdefinierade skadornas utbredning (nederst) som utgör 4 % av den totalt odlade arealen vete. Störst skador i det mörkaste gröna området noterades på ett 11 ha stort fält med totalt 14 % skadegrad och i det mörkaste röda området på samma fält knappt 3 % vildsvinsskador. Svarta punkter indikerar de inventerade fälten och representerar 24 % av alla vetefält samt utgör 27 % av den totala arealen odlad vete. Övriga förklaringar till kartornas framtagande framgår i 3.1 samt 4.2.3. Data insamlat sommaren 2024.

Jönköpings län – ÄFO 1 Nordöst, vete




Jönköping län – ÄFO 1 Nordöst, vete




Figur 4b. De AI-definierade och extrapolerade skadornas rumsliga utbredning i vete (ÄFO 1 Nordöst, Jönköpings län). De sammanlagda skadorna utgör 21 % av den totalt odlade arealen vete (överst) samt de vildsvinsdefinierade skadornas utbredning (nederst) som utgör 7 % av den totalt odlade arealen vete. Störst skador i det mörkaste gröna området noterades på ett 15 ha stort fält med totalt 31 % skadegrad och i det mörkaste röda på samma fält 12 % vildsvinsskador. Svarta punkter indikerar de inventerade fälten och representerar 26 % av alla vetefält samt utgör 25 % av den totala arealen odlad vete. Övriga förklaringar till kartornas framtagande framgår i 3.1 samt 4.2.3. Data insamlat sommaren 2024.


Södermanland – ÄFO-1, vete



Södermanland – ÄFO 1, vete



Figur 4c. De AI-definierade och extrapolerade skadornas rumsliga utbredning i vete (ÄFO 1, Södermanlands län). De sammanlagda skadorna utgör 20 % av den totalt odlade arealen vete (överst) samt de vildsvinsdefinierade skadornas utbredning (nederst) som utgör 6 % av den totalt odlade arealen vete. Störst skador i det mörkaste gröna området noterades på ett 49 ha stort fält med totalt 23 % skadegrad och i det mörkaste röda området på samma fält knappt 7,5 % vildsvinsskador. Svarta punkter indikerar de inventerade fälten och representerar 4 % av alla vetefält samt utgör 5 % av den totala arealen odlad vete. Övriga förklaringar till kartornas framtagande framgår i 3.1 samt 4.2.3. Den röda polygonen anger grovt flygförbudszonen, som inte kunde inventeras. Data insamlat sommaren 2024.




Figur 4d. De AI-definierade och extrapolerade skadornas rumsliga utbredning i vete (ÄFO Sydöstra, Örebro län). De sammanlagda skadorna utgör 14 % av den totalt odlade arealen vete (överst) samt de vildsvinsdefinierade skadornas utbredning (nederst) som utgör 4 % av den totalt odlade arealen vete. Störst skador i det mörkaste gröna området noterades på ett 6 ha stort fält med totalt 34 % skadegrad och i det mörkaste röda området på samma fält 11,5 % vildsvinsskador. Svarta punkter indikerar de inventerade fälten och representerar 4 % av alla vetefält samt utgör 9 % av den totala arealen odlad vete. Övriga förklaringar till kartornas framtagande framgår i 3.1 samt 4.2.3. Data insamlat sommaren 2024.

4.3 Validerade skador och träningsdata

Projektets bildbank eller träningsdata med validerade skador av olika ursprung på gräsmark genererade under 2024 sammanlagt 2 657 registrerade skador (sex klasser; Figur 5). Bildbankens träningsdata är tydligt obalanserad. Antalet validerade skador orsakade av vildsvin och maskinskadorna dominerar. Detta förklaras av att vårt mål under fältsäsongen 2024 var att framförallt träna AI-modulen på att skilja vildsvinsskador från maskinskadorna. Den särskiljningen har visat sig vara problematiskt under våra tidigare analyser baserat på träningsdata insamlad 2023. Under fältarbetet 2024 tilläts skadebesiktningspersonalen att ange 6 ytterligare skadeklasser utöver de 6 som redovisas i denna rapport, inklusive en grupp med ”annan skada” som ofta var av okänt ursprung eller mycket ovanlig, som t.ex. döda fläckar efter ensilagebalar eller före detta upplag efter avverkningar o.s.v. Sammantaget utgör dock denna kategori en stor del av bildbanken (Figur 5), medan de olika typerna av skadeorsaker var för sig var allt för sällsynta för att kunna träna AI-modulen på, som separata skadeklasser. Under säsongen 2023 samlades 3 944 bilder med validerade skador (sex klasser; Kjellander et al. 2024). Det innebär att projektets totala bildbank med validerade skador på gräsmark (träningsdata) med sex olika ursprung nu består av 6 601 bilder för AI-modulen att träna på. På vete är motsvarande siffror 3 615 bilder från 2024 (Figur 5) samt 6 719 från 2023 (Kjellander et al. 2024), totalt 10 334 bilder, uppdelat på sex klasser. Totalt består således bildbanken av totalt 16 935 bilder av validerade skador på gräsmark och vete (sex klasser).

Antal validerade bilder



Figur 5. Antalet validerade skador med olika ursprung på gräs- och vetefält insamlade 2024. Gruppen ”Annat” består huvudsakligen av grävling, stigar/gångar, så-mistor, liggsåd, brunnar samt oklara skador som inte med säkerhet kan hänföras till någon av de 6 skadeklasserna.

4.4 AI-modulens precision

Beskrivet i olika former av sk. ”Confusion matriser” redovisas här de sammanfattande resultaten av den för närvarande bästa AI-algoritmens prestanda. Matrisen läses så att varje kolumn redovisar det verkliga sanna och kontrollerade antalet skador av visst ursprung medan varje rad redovisar hur AI-modulen definierat samma skador. Data redovisas här på två sätt, antingen som antalet bilder (Tabell 7A & 8A) eller som andelen bilder (Tabell 7B & 8B). Detta redovisningssätt anses av många vara den mest ärliga och lättförståeliga formen, då den inte inkluderar krångliga statistiska analyser och begrepp.

Tabell 7A & B. En s.k. ”confusion matris” baserad på AI-tolkade skador i gräsmark (betes- och slåttervall) i fyra sydsvenska ÄFO:n, 2024, sammantaget. De AI-definierade skadeorsaker som bestämts korrekt och felaktigt anges som (A) antalet bilder och (B) andelen bilder. De skuggade rutorna anger när de AI-genererade skadorna sammanfaller med den verkliga skadeorsaken. Baserat på 2 657 verifierade skador med träningsdata insamlat 2024.

(A)		Verkliga skador						(B)		Verkliga skador					
		Hjort	Torka	Maskin	Sten	Vatten	Vildsvin			Hjort	Torka	Maskin	Sten	Vatten	Vildsvin
AI-tolkade skador	Hjort	78	2	15	3	0	45	AI-tolkade skador	Hjort	85 %	2 %	2 %	1 %	0 %	5 %
	Torka	0	59	7	3	5	16		Torka	0 %	62 %	1 %	1 %	1 %	2 %
	Maskin	4	6	639	1	36	95		Maskin	4 %	6 %	80 %	0 %	10 %	10 %
	Sten	2	5	19	324	4	166		Sten	2 %	5 %	2 %	81 %	1 %	18 %
	Vatten	3	18	45	4	288	98		Vatten	3 %	19 %	6 %	1 %	81 %	11 %
	Vildsvin	5	5	70	67	24	496		Vildsvin	5 %	5 %	9 %	17 %	7 %	54 %

Notera att i absoluta tal definierar algoritmen 1884 bilder av kända skador i gräsmark korrekt, av totalt 2 657 (71 % = Korrekthet; Kappa = 0,62; F1 = 0,69); Tabell 7A), jämfört med det totala antalet förutsägelser. Motsvarande siffror för enbart bestämning av vildsvinsskador på gräsmark är precisionen 74 % (Korrekthet = 76 %; F1 = 0,63). För tolkning av matrisen och den statistiska utvärderingen hänvisas till Bilaga 1.

Tabell 8A & B. En sk. "confusion matris" baserad på AI-tolkade skador i vete (höst- och vårsådd) i fyra sydsvenska ÅFO:n, 2024, sammantaget. De AI-definierade skadeorsaker som bestämts korrekt och felaktigt anges som (A) antalet bilder och (B) andelen bilder. De skuggade rutorna anger när de AI-genererade skadorna sammanfaller med den verkliga skadeorsaken. Baserat på 3 615 verifierade skador med träningsdata insamlat 2024.

(A)		Verkliga skador					
AI-tolkade skador		Hjort	Torka	Maskin	Sten	Vatten	Vildsvin
	Hjort	63	0	1	0	4	34
	Torka	1	101	2	0	15	14
	Maskin	2	3	1 048	1	19	18
	Sten	3	0	0	23	0	15
	Vatten	11	24	17	2	599	72
	Vildsvin	72	20	64	51	65	1 251

(B)		Verkliga skador					
AI-tolkade skador		Hjort	Torka	Maskin	Sten	Vatten	Vildsvin
	Hjort	41 %	0 %	0 %	0 %	1 %	2 %
	Torka	1 %	68 %	0 %	0 %	2 %	1 %
	Maskin	1 %	2 %	93 %	1 %	3 %	1 %
	Sten	2 %	0 %	0 %	30 %	0 %	1 %
	Vatten	7 %	16 %	2 %	3 %	85 %	5 %
	Vildsvin	47 %	13 %	6 %	66 %	9 %	89 %


Notera att i absoluta tal definierar algoritmen 3 085 bilder av kända skador i vete korrekt, av totalt 3 615 (85 % = Korrekthet; Kappa = 0,79; F1 = 0,71); Tabell 8A), jämfört med det totala antalet förutsägelser. Motsvarande siffror för enbart bestämning av vildsvinsskador på vete är precisionen 82 % (Korrekthet = 90 %; F1= 0.85). För tolkning av matrisen och den statistiska utvärderingen hänvisas till Bilaga 1.

4.5 Prognos för algoritmernas förbättrade prestanda


För att uppskatta mängden kompletterande träningsdata som krävs för att nå cirka 90 % korrekthet genomfördes en analys där modellen testades på successivt ökande mängder av befintligt träningsmaterial. Utvärderingen genomfördes med stegvisa ökningar från 1 % till 10 % och vidare uppåt, baserat på de knappt 17 000 bilder som idag finns tillgängliga (sammanlagt för gräsmark och vete).

Resultaten indikerar att en ökning av träningsdatamängden med en faktor på mellan 10 och 100 (beroende på gröda) kan komma att krävas för att uppnå den önskade noggrannheten (Figur 6 och 7). Prognosen förutsätter att bildinsamlingen fortsätter med samma struktur, det vill säga att samtliga sex definierade skadeklasser dokumenteras, samt att det inte uppstår oväntade variationer i skadornas utseende under fortsatt datainsamling.

För att effektivisera utvecklingen rekommenderas särskilt att fokus läggs på att komplettera datasetet med fler bilder av de i dagsläget underrepresenterade skadeklasserna, framför allt "hjortskador", "torka" och "sten" (se Figur 5).



Figur 6. Algoritmens möjlighet att korrekt bestämma sex olika skadekategorier i gräsmark (betes- och slåttervall) baserat på nuvarande antalet träningsbilder (markerad med röd pil) och hur algoritmen successivt prognostiseras att förbättrats i sin identifiering i takt med att antalet träningsbilder ökar. Linjen beskriver den mest sannolika utvecklingen av den fortsatta inlärningsprocessen. För att uppnå en godtagbar korrekthet (> 90 % korrekthet) krävs ca 100 gånger så många träningsbilder, än vad som finns tillgängliga idag.



Figur 7. Algoritmens möjlighet att korrekt bestämma sex olika skadekategorier i vete (höst- och vårsådd) baserat på nuvarande antalet tillgängliga träningsbilder (markerad med röd pil) och hur algoritmen successivt prognostiseras att förbättrats i sin identifiering i takt med att antalet träningsbilder ökar. Linjen beskriver den mest sannolika utvecklingen av den fortsatta inlärningsprocessen. För att uppnå en godtagbar korrekthet (> 90 % korrekthet) krävs ca 10 gånger så många träningsbilder, än vad som finns tillgängliga idag.

4.6 Tidsåtgång

Totalt tog det cirka 60 arbetsdagar att genomföra drönarflygning och analys av 100 fält av genomsnittlig storlek (Tabell 9). Detta är 5–10 dagar snabbare än motsvarande arbete under 2023 (Kjellander et al. 2024). Tidsbesparingen förklaras främst av att vi under 2024 flög på högre höjd (120 m jämfört med 40 m året innan) samt att bildanalysen förenklades genom att vi avstod från 3D-analyser. Fältarbetet tog under säsongen 2024 cirka 5 – 7 dagar per gröda för 100 fält. Vetefälten tog något längre tid att flyga eftersom de i genomsnitt är större än gräsfälten. Även landskapets utformning och hur jordbruksmarken är fördelad inom respektive ÄFO påverkar fältarbetet, då längre transportsträckor mellan fält förlänger arbetstiden.

På kontoret var digitaliseringen av skadorna (d.v.s. skapandet av valideringspolygoner) den mest tidskrävande delen. Även den datorintensiva processen att generera ortomosaiker tog betydande tid, och tidsåtgången är direkt kopplad till datorkapacitet. Träning av AI-modeller och själva klassificeringen av skador tog totalt 19 – 20 arbetsdagar. För analysen användes programmeringsspråket R. Med en mer kraftfull datormiljö och ett snabbare, mer maskinnära språk som C++ skulle samtliga analyssteg kunna kopplas samman och automatiseras och på så sätt effektiviseras. Detta skulle avsevärt minska arbetstiden – för ett enskilt fält skulle resultaten då kunna genereras nästintill omedelbart. Även i en vanlig, men kraftfull, PC-miljö kan ett helt fältmaterial om 100 fält bearbetas från råa drönarbilder till färdiga resultat på mindre än 10 timmar – förutsatt att systemet är fullt automatiserat. Dessa tidsåtgångsuppskattningar är osäkra och just uppskattningar, d.v.s. inte testade i praktiken.

Tabell 9. Tidsåtgång (antal arbetsdagar per 100 genomsnittliga fält per gröda) från datainsamling till färdigt resultat under 2024, samt en uppskattning av tidsåtgången vid ett mer förenklat arbetsflöde och kraftfullare datormiljö.

Arbetsmoment	Gräs	Vete	Framtida tidsåtgång
Fältarbete, drönarflygning	5	7	5–7
Fältarbete, markkontroll	5	7	0**
Ortomosaiker	13	15	–30 %
Digitalisering, skador	19	19	0**
Träning av AI	5,4*	7*	0
AI-skadeklassificering	14*	14*	3*
Totalt	61,5	69	~19

* Beroende av datorkapacitet och programspråk

** Förutsatt att ingen valideringsdata behöver samlas in

4.6.1 Använd hårdvara för bildanalys och AI-klassificering

Analyserna i denna studie genomfördes på två olika datorer; en stationär arbetsstation och en kraftfull bärbar dator.

Stationär dator:

- Modell: HP Z4 G5
- Processor (CPU): Intel Xeon W5-2465X, 16 kärnor, 4,5 GHz, 33,75 MB cache, 200 W
- Grafikkort (GPU): NVIDIA RTX A4500 med 20 GB videominne (GDDR6)
- Internminne (RAM): 128 GB DDR5 (4 x 32 GB ECC-minnen)
- Lagring: 2 TB supersnabb SSD-disk (NVMe PCIe Gen 4)
- Operativsystem: Windows 11 Pro (64-bit)

Bärbar dator:

- Modell: HP ZBook Fury 16 G11
- Processor (CPU): Intel Core i9-14900HX
- Grafikkort (GPU): NVIDIA RTX 3500 Ada med 12 GB videominne
- Internminne (RAM): 64 GB DDR5 (2 x 32 GB)
- Lagring: 1 TB SSD-disk (NVMe PCIe Gen 4)
- Operativsystem: Windows 11 Pro (64-bit)

5. Diskussion

Inventeringen genomfördes under odlingsssäsongen 2024 inom de viltrikaste älgförvaltningsområdena (ÄFO) i fyra län: Blekinge, Jönköping, Södermanland och Örebro. Datainsamlingen utfördes på fältnivå och skalades upp för att uppskatta genomsnittliga skadegrader och fördelning inom respektive ÄFO. Vi visar att det är fullt möjligt att med hjälp av drönare och AI identifiera och kvantifiera viltskador på jordbruksgrödor över stora arealer och att det redan nu kan göras med relativt hög precision. Den genomsnittliga skadegraden i de fyra inventerade ÄFO:na uppmättes till 17 % (± 5 %) i gräsmark (betes- och slåttervall) och lika mycket i vete (± 1 %). Träffsäkerheten i skadeklassificeringen uppgick till 71 % för gräsmark och 85 % för vete, med variationer beroende på gröda, skadetyper och mängden träningsdata. De AI-skattade vildsvinsskadorna var lägre (2 % i gräsmark och 5 % i vete) i jämförelse med vad som redovisats i tidigare enkätbaserade uppskattningar (SCB 2015, 2021, 2024). Resultaten visar också stora skillnader mellan olika fält och ÄFO:n, vilket understryker betydelsen av storskaliga, yttäckande metoder. Samtidigt identifierades vissa begränsningar, såsom bortfall av större fält och lägre precision för vissa skadetyper. Trots detta representerar metoden ett viktigt steg mot en mer standardiserad, objektiv och upprepbar viltskadeövervakning inom svenskt jordbruk.

Metoden erbjuder en rad fördelar jämfört med tidigare enkätundersökningar eller manuella tillvägagångssätt, särskilt vad gäller objektivitet, upprepbarhet och tidsmässig effektivitet. Att kunna samla in och analysera data från stora arealer inom snäva tidsfönster innebär ett betydande steg framåt för både vilt- och jordbruksförvaltningen. Samtidigt aktualiserar resultaten en rad metodologiska och tolknings-tekniska frågeställningar som bör diskuteras innan allt för långtgående slutsatser kan dras av de faktiska skattade skadorna. T.ex. inventerades endast 2 % av den odlade arealen gräsmark, vilket kan ifrågasättas ur ett representativitetsperspektiv. En diskussion om dessa behandlas även i avsnittet 5.1 om ”Begränsningar och rekommendationer”.

En annan utmaning rör metodens träffsäkerhet. Den varierar tydligt mellan grödor och skadetyper, vilket delvis kan förklaras av olika tillgång till träningsdata. Att algoritmen generellt presterar bättre på vete än på gräsmark understryker behovet av fortsatt modellträning, särskilt inom skadeklasser där precisionen idag är otillräcklig – exempelvis vad gäller hjortskador som endast identifierades i Sörmland (1 % skadegrad), och då med en av algoritmerna som visar lägre generell träffsäkerhet (Kleijkers et al., 2025). Skillnader i hur olika viltskador framstår påverkade uppenbart (även) denna skadeinventering. T.ex. lämnar vildsvin tydligare spår i form av skador i vete (grytor), vilket genererade mer träningsdata till AI-modellen. Hjortskador ger däremot ofta upphov till enstaka större skadepolygoner snarare än många små punkter. Detta kan delvis förklara vår snedfördelning i träningsdata, särskilt i områden som Södermanland där vildsvinsskador dominerar. Detta pekar på ett fortsatt behov av ytterligare insamling av träningsdata för att bättre kunna identifiera hjortorsakade betesskador. Det sätter dessutom gränser för hur generella slutsatser vi kan dra om skadornas omfattning och fördelning på nationell nivå. Att fortsätta bygga upp ett representativt och kvalitetssäkrat träningsdatabibliotek framstår därför som en av de viktigaste utvecklingsuppgifterna.

På gräsmark krävs kanske så mycket som 100 gånger mer träningsbilder för att nå 90 % träffsäkerhet.

Inventeringen har i praktiken också påverkats av logistiska begränsningar. Bortfallet av de allra största fälten (>20 ha), ofta på grund av tidsbrist och sviktande ljusförhållanden, är inte slumpmässigt och kan ha påverkat skattningarna. Eftersom större fält generellt anses drabbas mindre av viltskador finns en risk att denna något skeva representation av fältstorlek ger en överskattning av genomsnittlig skadegrad. Samtidigt är det också i mindre fält som ekonomiska skador per hektar kan bli mest kännbara för den enskilde lantbrukaren.

Tidsaspekten är central för att metoden ska få praktisk betydelse i förvaltningen. I denna studie kunde skador skattas just före skörd, vilket ger god överensstämmelse med faktisk skördeförlust, särskilt i spannmål. Men för att metoden också ska bli ett verktyg i det förebyggande arbetet, krävs att datainsamling och analys kan ske tidigare under säsongen, exempelvis i samband med den första vallskörd och i god tid inför spannmålets mjölkmodningsstadium. En automatiserad inventering, där resultat kan återkopplas momentant, möjliggör även proaktiva åtgärder som jakt, skrämsel och stängsling innan grödan når skadebegärliga stadier (mjölkmodnad i spannmål). Till exempel skulle skadegraden (vildsvinsbök) i gräsmarker före första vallskörd kunna fungera som en varningssignal inför resten av odlingssäsongen – under förutsättning att inventeringen sker snabbt och vid rätt tidpunkt och att tidiga skador är korrelerade med skador senare på säsongen. Detta ställer dock krav på både flygkapacitet, moln-baserad beräkning och ett effektivt återrapporteringssystem. Det finns en stor potential, men också stora utvecklingsbehov (Blom & Broby, 2024).

Den totala tidsåtgången i denna studie – cirka 60 arbetsdagar per 100 genomsnittsfält – illustrerar både metodens genomförbarhet och dess nuvarande begränsningar. Om metoden skulle skalas upp till att täcka samtliga älgförvaltningsområden (ÄFO) i exempelvis Örebro län, där varje ÄFO inventeras med motsvarande fälttäthet (ca 100 fält per område), skulle analysarbetet snabbt växa till flera hundra arbetsdagar, även med en effektiv organisation. Samtidigt finns det flera faktorer som talar för att denna tidsåtgång kan reduceras kraftigt vid framtida tillämpningar. Redan i denna studie ser vi att användning av högre flyghöjd, enklare bildprocessering (ingen 3D-modellering) och mer optimerad programmering lett till tydliga tidsvinster jämfört med föregående år.

Vid en framtida tillämpning i större skala skulle tidsbesparingar kunna uppnås genom att initialt endast genomföra markkontroll på en mindre andel fält (exempelvis 1–10 %, vartannat år för att vidmakthålla metodens trovärdighet bland avnämarna), vilket i kombination med förbättrad AI-modellering, kan minska behovet av manuell digitalisering (av skador). Även övergång till 2D-flygning över spannmål (där fälten är större och mer homogena) skulle bidra till snabbare inventering i fält. En kraftfullare datormiljö, där flera analyssteg automatiseras och parallelliseras, gör det dessutom möjligt att bearbeta stora datamängder betydligt mer effektivt.

Ytterligare rationalisering kan uppnås genom att använda flygplan med känsligare sensorer, vilket minskar bildmaterialets variation och därmed behovet av omfattande kalibrering. Färre, men mer informativa bilder, innebär också minskad lagrings- och bearbetningstid. En sådan utveckling skulle inte bara reducera den totala arbetsinsatsen utan också minska personberoendet i både fältarbete och analys (se 5.1 – Begränsningar och rekommendationer), vilket är en viktig faktor för metodens långsiktiga standardisering och bredare tillämpning.

Det bör vidare uppmärksammas att denna metod främst fångar synliga skador från ovan strax före skörd. Det innebär att vissa viltskador riskerar att förbises (t.ex. äldre bök/trampskador i gräsmark samt bete under höst, vinter, vår på vetebrodd). Å andra sidan finns också en risk för övertolkning, där andra störningar än vilt (t.ex. vattenstress, insektsskador, maskinskadade eller näringsbrister) feltolkas som vilt-skador, särskilt vid brist på referensbilder från olika skadeorsaker. Kalibreringen mot markdata, liksom vidareutveckling av skadeklassificeringar, är därför avgörande.

Att kvantifiera produktionsförluster i termer av förlorad biomassa till följd av betesskador i vall och spannmål är en metodologisk utmaning, särskilt när skadorna orsakas av hjort eller fågel. Dessa skador är ofta diffusa och svåra att identifiera i fält. På gräsmark är det i praktiken omöjligt att markera specifika betade områden, såvida det inte rör sig om extrema fall. Även i spannmål är skadorna ofta subtila, särskilt när de orsakas av enstaka hjortskador, och som dessutom kan förekomma i kombination med skador orsakade av andra arter, vilket komplicerar tolkningen ytterligare.

En 3D-tolkning av enskilda fälts biomassaproduktion kan potentiellt användas för att uppskatta biomassaförlusten inom samma fält, genom att jämföra skadade och oskadade delar. Denna metod är dock oprövad och kommer att vara resurskrävande – både tidsmässigt och ekonomiskt – jämfört med den enklare 2D-analys, vi nu använt.

Slutligen visar resultaten på betydande variationer mellan fält och mellan ÅFO:n. Det understryker hur ojämn vilttillgången är i landskapet och förklarar samtidigt varför många lantbrukare upplever viltskador som lokalt mycket allvarliga – även om nationella genomsnitt kan ge ett annat intryck. Denna variation bekräftar behovet av just yttäckande inventeringar, där skadebilden kan sättas in i ett större sammanhang och ligga till grund för mer lokalt riktade förvaltningsinsatser.

Sammanfattningsvis visar denna studie att tekniken har stor potential, men också att den är i behov av fortsatt effektivisering, validering, kalibrering och anpassning till olika grödor, landskapstyper och förvaltningsbehov. Den bör därför tills vidare ses som ett viktigt komplement till – snarare än ett fullständigt ersättande av andra datakällor och metoder i viltförvaltningen. Med fortsatt metodutveckling kan detta dock komma att bli ett bärande verktyg i en framtida nationell viltskadeövervakning.

5.1 Begränsningar och rekommendationer

5.1.1 Fältdata

- Klassificeringen av skadetyper förändrades mellan 2023 och 2024, vilket skapade en obalans i träningsdata. Den frekventa användningen av en ny kategori "Annat" fick tyvärr till följd att ett stort antal validerade skador inte kunde användas för att träna modellen.
- Övergången från analys av 3D-bilder till 2D-bilder av spannmål sparar mycket tid, såväl vid flygtillfället som i den senare analysfasen. Här finns dock en risk att möjligheterna att beräkna skördeförlusterna kan påverkas. Detta behöver utvärderas ytterligare.
- Ändrade flyginställningar (från 40 meters höjd till 120 meters höjd och därmed en lägre upplösning från 5 till 8 cm per pixel i ortomosaikerna), samt metoden för val av fält ändrades mellan fältsäsongerna 2023 och 2024. Under 2023 plockades specifikt vildsvinsskadade fält ut medan under 2024 var det ett helt randomiserat

urval av fält, där vissa skadeorsaker var mycket ovanliga. Dessa förändringar bidrog till s.k. heterogenitet i indata och ett större behov av träningsdata för algoritmerna.

- Datakvaliteten (d.v.s. drönar-bilderna) påverkades av externa faktorer såsom väderförhållanden och variation i de olika piloternas arbetssätt. T.ex. avbröts drönarflygningen vid olika tider och krav på ljusförhållanden och vindstyrka.
- Skillnader i erfarenhet mellan drönarpiloter och den fältpersonal som koordinerade de validerade skadorna på respektive fält bidrog till variation i datainsamlingen och koordinatsättning. T.ex. skadevaliderades fält som aldrig flögs med drönare.
- Skadeklassificeringens heterogenitet i fält förklaras av dess delvis subjektiva natur. Ju fler olika personer som genomför skadeklassificeringen, desto högre heterogenitet i datasetet.
- Inventeringen i Örebro län, genomfördes av oss själva och dess resultat uppvisar högst grad av standardisering, klassificering och därmed bäst precision m.m.

5.1.2 Modellutformning

- Den nuvarande AI-modellen kräver omfattande datorkapacitet för att fungera effektivt.
- Det datorberoende systemet är semi-automatiskt, vilket innebär att en mänsklig operatör måste genomföra vissa steg för hand, samt därefter validera resultaten i varje steg. Detta ökar risken för mänskliga fel.
- AI-modellen använder s.k. "convolutional neural network" (CNN) från VGG16-modellen (Simonyan och Zisserman 2014) samt data från ImageNet-datasetet (Deng et al. 2009) för att artificiellt förbättra prestandan. AI-modellen kräver mer data för att kunna förbättra dess prestandan enbart baserat på egna dataset.
- Modellen är skriven i programspråket "R" och är beroende av externa programpaket, vilket medför vissa begränsningar i algoritmisk flexibilitet, optimering, generaliseringsförmåga och prestanda.
- Hittills har endast CNN-baserad s.k. "deep learning" implementerats, men andra inlärningsmodeller (t.ex. self-supervised learning (SSL), Mask R-CNN, Recurrent Neural Networks (RNN och LSTM), etc.) förmåga att identifiera skador kan också undersökas.
- Det råder (fortfarande) en betydande brist på träningsdata för vissa specifika skador, vilket påverkar AI-modellens tillförlitlighet.

5.1.3 Rekommendationer

- Lägg stor vikt vid att inte bara harmonisera fältdata-insamlingen med drönarinventeringen utan var noggrann med uppmärksamheten av insamlade fältdata. Fastställ ett detaljerat och standardiserat protokoll före varje inventering/fältsäsong för att undvika missförstånd och minska variationen i datakvalitet och -kvantitet.
- Öka mängden insamlade data avsevärt, inklusive utvidgning av studieområden, fält och träningsdata (bilder på validerade skador). Bättre täckning och representativitet i datasetet kommer att förbättra modellens generalitet, noggrannhet och tillförlitlighet.

- En mer genomgripande utvärdering av stickprovsförfarandet, d.v.s. antalet och andelen fält som slumpas ut för inventering, är nödvändig om metoden ska appliceras över större områden.
- Överväg att skala upp modellen till nationell nivå genom att inkludera flygburna data som ett alternativ till drönarbilder. Detta skulle kunna förbättra den insamlade datans enhetlighet och dessutom möjliggöra användning av större/tyngre och mer avancerade sensorer (t.ex. LiDAR, hyperspektral bildbehandling, kameror med högre upplösning osv.), vilket höjer datakvaliteten.
- Bestäm om rådata ska lagras, vilket kräver stor lagringskapacitet. Att behålla rådata ger flexibilitet för framtida användning och gör det möjligt att anpassa modellen till nya syften.
- För att skala upp modellen krävs högpresterande beräkningskapacitet. Detta kan uppnås genom att bygga upp en infrastruktur internt eller genom samarbeten med externa datacenter. Detsamma gäller för lagringslösningar.
- Vidare utveckling av modellen bör ske i samverkan mellan ekologisk expertis (särskilt inom svenskt jordbruk) och avancerad programmeringskompetens.
- Ytterligare algoritmer (t.ex. SSL, Mask R-CNN, RNN och LSTM) bör utforskas och utvärderas för att undersöka om de kan komplettera, justera eller helt ersätta den nuvarande modellutformningen.
- Fokusera på att förbättra modellens automatisering för att minska risken för mänskliga fel. Det kommer dessutom att sänka driftskostnaderna, förbättra prestanda och bearbetningstid.
- Överväg att skriva om modellen i ett programmeringsspråk som stödjer s.k. ”hårdkodning”, såsom C++, för att såväl förkorta analysfasen, förbättra prestanda, anpassningsförmåga och optimering vid framtida användning och eventuell vidareutveckling.

6. Tack till

Samtliga drönapiloter (särskilt Gerdes Solutions AB) för deras professionella insatser i fält, och till alla markägare som upplåtit sina marker – med särskilt omnämnande av Boo, Hörningsholm och hundratals andra generösa fastighetsägare. Till Länsstyrelsen i Jönköpings län för värdefullt ekonomiskt bidrag och praktiskt engagemang i projektet. Tack också till de studenter som deltagit i datainsamling och analys, samt till de besiktningsmän som hjälpt till med inventering av skador i gröda – särskilt Robert Briland, vars erfarenhet och noggrannhet varit ovärderlig. Slutligen tack till Jordbruksverket för att ha möjliggjort tillgång till blockdatabasen, vilket varit avgörande för vårt arbete.

7. Referenser

- Bergvall, UA., Kjellander, P. & Jarnemo, A. 2022. Nationella och internationella erfarenheter av inventeringsmetoder för vildsvinsskador: En kunskapssammanställning. Naturvårdsverket 7024.
(<https://www.naturvardsverket.se/publikationer/7000/978-91-620-7024-3/>)
- Blom, P. & Broby, A. 2024. Införande av ny metodik för inventering av viltskador på gröda – Verksamhetsanalys och förslag till fortsatt arbete. Naturvårdsverket. Uppdragsleverans, Ärendenr. NV-04194-24.64pp.
- Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., and Fei-Fei, L. 2009. Imagenet: A large-scale hierarchical image database. In Proc. CVPR. DOI: 10.1109/CVPR.2009.5206848
- Kjellander, P., Rumiano, F., Månsson, J. & Norström, A. 2024. En standardiserad inventeringsmetod för att uppskatta skador på gröda – Med fokus på vilt- och vildsvinsskador. Rapport, SLU, Inst. för ekologi. 38pp. DOI: 10.54612/a.2fjbv2ivoo
- Kleijkers, Y, Rumiano, F. & Kjellander, P. 2025. A Deep Learning Approach Using Convolutional Neural Networks for Discriminating Damage Types in Agricultural Wheat and Grasslands. <https://doi.org/10.54612/a.176cfqd5in>
- LRF. 2022. Toleransnivå för viltskador i jordbruket. Lantbrukarnas Riksförbund, Rapport – 220317. 21 sidor.
- SCB. 2015. Viltskador i lantbruksgrödor 2014. <https://jordbruksverket.se/om-jordbruksverket/jordbruksverkets-officiella-statistik/jordbruksverkets-statistikrapporter/statistik/2020-06-22-viltskador-i-lantbruksgrödor-2014>
- SCB. 2021. Viltskador i lantbruksgrödor 2020. <https://jordbruksverket.se/om-jordbruksverket/jordbruksverkets-officiella-statistik/jordbruksverkets-statistikrapporter/statistik/2021-07-06-viltskador-i-lantbruksgrödor-2020>
- SCB. 2024. Viltskador i lantbruksgrödor 2023. <https://jordbruksverket.se/om-jordbruksverket/jordbruksverkets-officiella-statistik/jordbruksverkets-statistikrapporter/statistik/2024-06-18-viltskador-i-lantbruksgrödor-2023>
- Simonyan, K., & Zisserman, A. 2014. Very deep convolutional networks for Large-Scale image recognition. arXiv (Cornell University).
<https://doi.org/10.48550/arxiv.1409.1556>

Bilaga 1 – Algoritmers statistiska tillförlitlighet

Confusion matrix

Svenska: Förväxlingsmatris eller Konfusionsmatris

Beskrivning: En tabell som visar antalet sanna positiva (TP), falska positiva (FP), sanna negativa (TN) och falska negativa (FN).

Användning: Grunden för att beräkna flera andra mått.

Precision

Svenska: Precision eller Träffsäkerhet

Formel: $\text{Precision} = \text{TP} / (\text{TP} + \text{FP})$

Beskrivning: Andelen korrekta positiva förutsägelser bland alla positiva förutsägelser.

Recall

Svenska: Återkallelse eller Känslighet

Formel: $\text{Recall} = \text{TP} / (\text{TP} + \text{FN})$

Beskrivning: Hur stor andel av de faktiska positiva fallen som identifierades korrekt.

F1-score

Svenska: F1-mått eller F1-poäng

Formel: $\text{F1} = 2 * (\text{Precision} * \text{Recall}) / (\text{Precision} + \text{Recall})$

Beskrivning: Det harmoniska medelvärdet av precision och recall. Används särskilt när man vill väga falska positiva och falska negativa lika.

Accuracy

Svenska: Noggrannhet eller Träffsäkerhet

Formel: $\text{Accuracy} = (\text{TP} + \text{TN}) / (\text{TP} + \text{TN} + \text{FP} + \text{FN})$

Beskrivning: Andelen korrekta förutsägelser totalt sett.

Cohen's kappa

Svenska: Cohens kappa – samstämmighet justerad för slumpen

Formel: $k = (p_o - p_e) / (1 - p_e)$, där p_o är observerad överensstämmelse och p_e är förväntad överensstämmelse pga slumpen.

Beskrivning: Ett mått på överensstämmelse mellan två bedömare ("modellen" och "sanningen"), justerat för den överensstämmelse som kan förväntas av ren slump.

Tolkning:



0 = ingen bättre än slumpen

1 = perfekt överensstämmelse



Negativa värden = sämre än slumpen

Bilaga 2 – Fältens rumsliga fördelning, ÄFO-nivå



Två delvis olika metoder (beroende på gröda) användes för att slumpa ut fält för inventering av skador. Först identifierades eventuella förekomster av flygförbuds-zoner inom respektive ÄFO. Efter att den arealen räknats bort och till följd av vetefältens klumpade fördelning, identifierades 10 kärnområden där merparten av ÄFO:ts vetefält förekom. Gräsmarkernas fördelning är däremot mer jämnt fördelade vilket innebar att respektive ÄFO kunde delas in i 10 jämnstora områden. Båda indelningarna gjordes med rumslig analys i GIS baserad på Jordbruksverkets blockdatabas. Inom respektive 10 delområden slumpades därefter 15 fält ut för inventering enligt beskrivningen i 3.1.



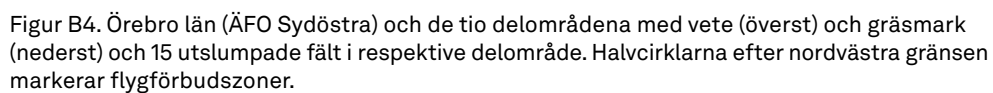
Figur B1. Blekinge län (ÄFO Öst), och de tio delområdena med vete (överst) och gräsmark (nederst) och 15 utslumpade fält i respektive delområde.



Figur B2. Jönköpings län (ÄFO 1 Nordöst), och de tio delområdena med vete (överst) och gräsmark (nederst) och 15 utslumpade fält i respektive delområde. Cirkeln i sydost markerar en flygförbudszon.



Figur B3. Södermanlands län (ÄFO 1), och de tio delområdena med vete (överst) och gräsmark (nederst) och 15 utslumpade fält i respektive delområde. Polygonen markerar en flygförbudszon.



Rapporten uttrycker nödvändigtvis inte
Naturvårdsverkets ställningstagande.
Författaren svarar själv för innehållet
och anges vid referens till rapporten.

Drönarinventering av vildsvinsskador på gröda

Inventering av gräsmark (betes- och slåttervall) och vete
i fyra ÄFO:n i södra Sverige, 2024

Denna rapport beskriver en standardiserad metod för att mäta skador i gröda orsakade av vilt med fokus på vildsvin samt de mätresultat denna metod gett i fyra olika älgförvaltningsområden under 2024. Rapporten bygger på det arbete SLU på Naturvårdsverkets uppdrag utfört med anledning av regleringsbrevet för budgetåret 2022 avseende Naturvårdsverket. I regleringsbrevet anges att *”Naturvårdsverket ska utifrån genomförd kunskapssammanställning och utifrån svenska förhållanden utveckla en standardiserad metod för att inventera skador i gröda orsakade av vildsvin. Uppdraget ska slutredovisas till Regeringskansliet (Näringsdepartementet) senast den 15 oktober 2024.”*

Denna rapport är skriven på uppdrag av Naturvårdsverket och författarna ansvarar själva för innehåll, slutsatser och eventuella rekommendationer. Det är Naturvårdsverkets förhoppning att den standardiserade metod att mäta skador i gröda som beskrivs och som har använts för att få fram de resultat som redovisas i rapporten kan bidra till ökad kunskap om hur stora skador i gröda orsakade av vilt är, men även vilka behov av ytterligare utveckling av metoden som krävs för att den ska kunna införas i större skala. Kunskap om de faktiska skadorna kan förhoppningsvis vara till hjälp i arbetet med förvaltningen av svenskt klövvilt och den samverkan och de samråd som behövs för en viltförvaltning som balanserar brukandet av vilt som resurs med de skador viltet orsakar. Arbetet har finansierats via Naturvårdsverkets anslag för åtgärder för värdefull natur.