

Statusnotat AP2 – 8556 Lejesædsprojekt

Baggrund

Biomasse i foråret har vist sig at være en god og objektiv indikator for efterfølgende risiko for lejesæd i vinterhvede. Udfordringen med den eksisterende model er, at landmanden skal bidrage med mange oplysninger, og derfor anvender mange landmænd stadig en visuel risikovurdering i marken. En ny model som udelukkende er baseret på biomassedata målt fra satellit, vil effektivisere og forbedre beslutningsgrundlaget for brug af vækstreguleringsmidler.

Målet med projektet

At udarbejde en model der kan bruges til at forudsige lejesæd i vinterhvede ud fra satellitbilleder af markens biomasse i det tidlige forår, så man kan målrette vækstreguleringsbehandlinger i de marker hvor modellen vurderer en høj risiko for lejesæd, og undlade vækstregulering i de marker hvor der lav risiko.

Resultater og konklusion

Anvendelse af kunstig intelligens til udvikling af en model, der skal forudsige og finde lejesæd i vinterhvedemarken med lejesæd er startet i 2022 og er fortsat i 2023.

Der er udarbejdet to nye modeller på baggrund af satellitbilleder af biomassen i marker i 2019. Én model som skal finde marker hvor der er opstået lejesæd i vinterhvede. Den anden model skal forudsige hvor der kan opstå lejesæd i vinterhvede på baggrund af markens biomasse i foråret.

Modellerne er søgt valideret ved at ringe til landmænd for at få af- eller bekræftet fund af lejesæd i et udvalg af de marker hvor modellerne siger at der enten er lejesæd eller kunne opstå lejesæd. Modellerne er ikke tilstrækkeligt gode endnu, men med materiale fra flere marker og år søges det at forbedre modellerne i 2023.

Herunder beskrives arbejdet med udarbejdelse og validering af modeller.

Annoteringsarbejde

Det indledende datagrundlag for modelarbejdet er blevet udført i 2022 og 2023 og består af primært 0,5 x 0,5 meters høj-opløsnings RGB-satellitbilleder fra SPOT, DG og Pleiades satellitter over knap 600 marker fra 2019, hovedsageligt marker med afgrøderne vinterhvede og vinterhybridrug.


For at danne et træningsdatasæt til en maskinlæringsmodel som skulle kunne detektere og/eller forudsige lejesæd, blev der anvendt en K-means clustering tilgang for at detektere 25 forskellige farvegrupper (K=25) i satellitbillederne. Disse farvegrupper er efterfølgende manuelt blevet inspiceret for hvert billede og kun de farvegrupper som har korresponderet til lejesæd på markerne, er blevet beholdt. Hvis en høj-opløsningspixel i billedet har tilhørt én af disse lejesædsfarvegrupper, så er denne pixel blevet annoteret med værdien 1 som indikation for lejesæd.



Figur 1 Farveannotering af lejesæd på baggrund af luftfotos.

Downsampling

Da al geospatialt modelleringsarbejde sker med satellitbåndene fra Sentinel Hub som udbydes i 10 x 10 meters opløsning, måtte de nu høj-opløsnings annoteringer *downsamples* til 10 x 10 meters opløsning. Hertil blev metoden at aggregere til 10 x 10 meters annoteringer ved at tage et gennemsnit over alle høj-opløsningspixels indenfor et vilkårligt 10 x 10 meters pixel i det anoterede satellitbillede. Således blev lejesædsannoteringerne transformeret fra høj-opløsning til den lavere 10 x 10 meters opløsning, hvori annoteringerne grundet aggregeringsmetoden nu bestod af grænseværdier fra 0 til 1. Desto tættere annoteringsgrænseværdien er på 1, desto flere høj-opløsningspixels indeholdt i det større 10 x 10 meters pixel havde således haft en lejesædsindikationsværdi på 1, hvilket er illustreret på figuren herunder.



Figur 2 Lejesædsindikationsværdier omsat til 10x 10 meters opløsning

STØTTET AF


Promilleafgiftsfonden for landbrug

Feature Engineering til maskinlæringsmodel

Ud fra Sentinel Hub's mest skyfrie billede taget mellem 20. juli og 5. august i 2019, blev alle tilgængelige satellitbånd downloadet i 10 x 10 meters opløsning for hvert markpolygon i det nu anoterede datasæt. Ud fra de rå farvebånd blev følgende afledte satellitbånd beregnet; Gråskala (grey easy), VARI, NDVI, NDRE, RDVI, GDVI, EVI, CIRE, SLAVI, REP, og inkluderet i datasættet. Inde for hver mark blev der også udregnet aggregerede værdier som gennemsnit, minimum, maksimum samt 15, 30, 60 og 85 kvantiler og benyttet som variabler. Slutteligt blev der beregnet relative værdier imellem hver pixel på marken samt alle tilhørende aggregerede værdier (f.eks.: Gråskala værdien i vilkårlig 10 x 10 meters pixel divideret med gråskala-gennemsnittet for hele marken). Foruden variabler som Northing (N) og Easting (E) koordinater samt afgrødetypen, så udgjorde resultatet af denne feature engineering-proces i alt 330 variabler i datasættet hvor vi modellerer på 10 x 10 meters pixelniveau.

Træning af detektionsmodel

Det samlede datasæt hvor hver række korresponderer til et (N, E)-koordinat for en 10 x 10 meters pixel indeholdt over 600.000 rækker fra 581 marker. Dette datasæt blev splittet således at 58 (ca. 10 %) tilfældige marker blev holdt ude og gemt som testsæt, hvor en detektionsmodel blev trænet til at klassificere lejesæd i hver 10 x 10 meters pixel. Modelvalget faldt på CatBoost som er en gradient-boosting maskinlæringsmodel, der er specielt designet til at håndtere kategoriske variabler (såsom afgrødetype). Den bruger en optimeret algoritme til at håndtere træning og forudsigelser, hvilket gjorde at den var effektiv at bruge. Klassificeringsproblemet indledende resultater viste at en lav grænse på 0,01 i afrundingen af anoteringsgrænseværdierne til enten 0 eller 1 forbedrede modellens detektionsevne ift. den mere arbitrære grænse på f.eks. 0,5. For at forhindre overfitting-problematikken blev der foretaget en feature-eliminering procedure indtil de 20 vigtigste variabler samt N, E og afgrødetypen var tilbage. Yderligere blev der optimeret for et valg af detektionsgrænseværdien ud fra F1-score metrikken, og således blev denne grænse sat til 0,63. Minimal hyperparameter tuning blev også foretaget via krydsvalidering, men denne tuning resulterede ikke i markante forbedringer i modellens detektionsevne.



Figur 3 Testsæt detektioner: Gul er lejesædsannoteringer, blå er modeldetektioner og grøn er hvor disse er enige

STØTTET AF

Ud fra ovenstående valg og erfaringerne endte modellen med at have følgende precision, recall, F1-score, accuracy og gennemsnit, figur 4. Klasse 0 er ingen lejesæd og klasse 1 er lejesæd.

	precision	recall	f1-score	support
0	0.91	0.88	0.89	54419
1	0.75	0.79	0.77	24378
accuracy			0.85	78797
macro avg	0.83	0.84	0.83	78797
weighted avg	0.86	0.85	0.85	78797

Figur 4 Vurdering af lejesædsmodellens evne til at finde lejesæd

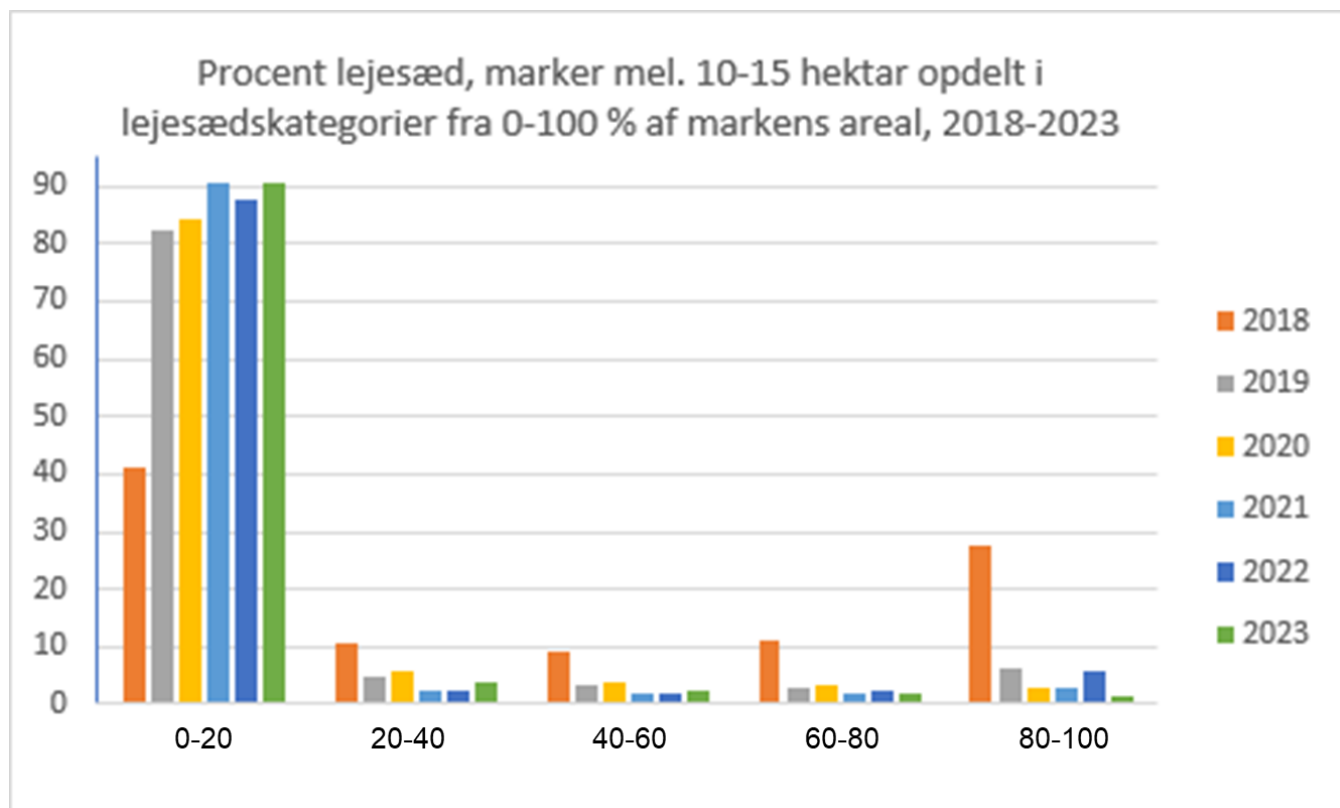
Precision måler, hvor mange af de detekterede positive tilfælde faktisk var positive. Så for klasse 0 var 91% af de tilfælde, der blev forudsagt som klasse 0, korrekte, og for klasse 1 var 75% af de tilfælde, der blev detekteret som klasse 1, korrekte. *Recall* måler, hvor mange af de faktiske positive tilfælde blev korrekt detekteret. For klasse 0 blev 88% af de faktiske klasse 0-tilfælde korrekt detekteret, og for klasse 1 blev 79% af de faktiske klasse 1-tilfælde korrekt detekteret. *F1-scoren* er det harmoniske gennemsnit af precision og recall. Den giver en balance mellem precision og recall, og er derfor i mange klassifikationsproblemer den metrik man ønsker at maksimere. For klasse 0 er F1-scoren 0,89, og for klasse 1 er den 0,77.

Support er antallet af faktiske forekomster af hver klasse i testdatasættet. Der er 54.419 tilfælde af klasse 0 og 24.378 tilfælde af klasse 1. *Accuracy* på 0,85 (85%) måler samlet korrektheden/nøjagtigheden af modellens detektioner. I dette tilfælde har modellen en nøjagtighed på 85%, hvilket betyder, at den korrekt forudsagde klassen for 85% af tilfældene i testdatasættet. *Macro avg* er det uvægtede gennemsnit af præcision, recall og F1-score for begge klasser. *Weighted avg* er det vægtede gennemsnit af præcision, recall og F1-score, hvor hver classes bidrag vægtes efter dens support.

Planet.com satellitbilleder fra årene 2018-2023

Med udgangspunkt i de lovende detektionsresultater fra det mindre datasæt i 2019 blev det besluttet at indkøbe billeder fra Planet.com af den lavere 3 x 3 meters opløsning over tusindvis af marker igennem adskillige år. Markerne af interesse blev begrænset til marker med afgrødetypen vinterhvede og marker i størrelsesordenen 8-15 hektar. Detektionsmodellen blev anvendt på downloadet Sentinel Hub data – igen fra kort før høstperioden – over alle tilgængelige markpolygoner der opfyldte disse kriterier igennem årene 2018-2023, og igen blev der detekteret lejesæd gennem kun de vigtigste variabler som udnævnt fra den tidligere beskrevet feature-elimineringssprocedur. Detektionsmodellen gav i alle årene med undtagelse af 2018 en lejesædsfordeling hvor 80-90 % af markerne havde en lejesædsandel på under 20%. I 2018 viste modellen en andel på cirka 60 % af arealet med lejesæd på mere end 20 % af arealet, figur 5. Året 2018 var som bekendt ekstremt tørkeramt og kan af flere årsager derfor være et "outlier år" med store farveforskelle i markerne ift. andre år op til den normale høstseson for vinterhvede. Farveforskellene forventes at være forklaringen på den markante fejlbedømmelse af marker med lejesæd, da der i praksis

ikke har været ret meget lejesæd i 2018. 2019 har derimod været et år meget lejesæd, og er det år af de seks år i undersøgelsen hvor der har været mest lejesæd.



Figur 5. Lejesædsmodellens bud på en fordeling af lejesædskategorier for 50.000 marker i 2018-2023

Med udgangspunkt i detektionsmodellen lejesædsklassificeringer, blev der i hvert år (2018-2023) taget en stratificeret tilfældig stikprøve på 50.000 hektar (ca. 5000 marker) eftersom der er i 2023 er indgået en aftale med Planet.com om en downloadkvota på maksimum 350.000 hektar resulterer denne stikprøvestrategi i en bufferkvota med et hektaromfang på 50.000 (= 350.000 – 50.000 * 6 år). Downloadkode der kalder Planet.com's API og downloader satellitbilleder *clipped* til vores markpolygoner/areas of interest (AOIs) er dannet og testet. Desværre er Planet.com's API ikke moden nok til at garantere skyfrie clipped AOIs da deres *visible_percent* filtreringsmekanisme ifølge en Planet.com ingeniør på nuværende tidspunkt stadig blot virker på scene/satellitbillede-niveau og ikke AOI-niveau.

Testdownloads af billeder over marker fra årene 2018-2023 blev foretaget og der blev downloadet billeder med en variation i lejesædsfordeling ifølge detektionsmodellen som hele spektret fra 0-100 % lejesæd. Figuren herunder viser et eksempel på en selekteret mark som modellen vurderede at der var lejesæd på, og hvor disse lejesædsdetektioner på marken blev angivet.



Figur 6 Planet.com testdownload af mark fra 2019 hvor grønne prikker indikerer modellens lejesædsdetektioner

Validering af detektionsmodellen

Der er blevet lavet et tilfældigt udvalg af billeder for 2023 for marker der lå i de fem kategorier med lejesæd som vist i tabel 1. Valideringen er sket ved at ringe op til brugerne af de specifikke marker og spørge dem om der var lejesæd i marken i 2023. Hvis der var, så er de blevet bedt om at estimere procentdelen med lejesæd. Resultaterne for 58 marker ses i tabel 1, og som det fremgår har indgruppering af markerne været korrekte for 36 % af markerne. Ud af de i alt 58 marker havde kun 6 marker lejesæd på en andel på mellem 20-100 %. Modellens estimat var 42 marker tilsammen i disse kategorier, så for disse kategorier alene var det 14 % af markerne der var rigtig vurderet af modellen. Da opringningerne blev lavet i efteråret 2023 i samme år som der blev spurgt ind til, så blev det vurderet at brugerne nemt kunne huske om der var lejesæd eller ej. Det kunne dog være lidt svært for dem iflg. deres egne udsagn at sætte den korrekte procentsats på. 86 % af markerne i den rigtige kategori hvor der var fra 0 til 20 % lejesæd.

Lejesæd	Sandt	Falsk
	Antal marker	Antal marker
80-100 procent lejesæd	1	9
60-80 procent lejesæd	1	7
40-60 procent lejesæd	2	9
20-40 procent lejesæd	2	12

STØTTET AF

Promilleafgiftsfonden for landbrug

0-20 procent lejesæd	15	0
I alt	21 (36%)	37 (67) %

Tabel 1. Validering af lejesædsmodel (detektionsmodel) på baggrund af opringning til landmænd.

Dette eksempel af flere 3 x 3 meter Planet.com billeder er repræsentativt for alle de eksempler på lejesæd som ses i træningsdatasættet til detektionsmodellen fra 2019, og det viser nogle tydelige farveforskelle mellem den mørkegrønne biomasse og de lysere områder hvor der er lejesæd. En udfordring vi fandt ved denne tilgang til selektering af Planet.com billeder var at der på adskillige marker og billeder fra Planet.com fandtes farveforskelle som ikke eksisterede i træningsdatasættet for detektionsmodellen. Eksempler på sådanne marker ses herunder, hvor der var farveforskelle i brune, rødlige og orange nuancer. Da modellen ikke er trænet til at klassificere lejesæd på disse farvenuancer, har den været udfordret mht. at klassificere lejesæd i disse marktyper. Noget tyder på at en del af de fejlskønnede marker med lejesæd i stedet for har huller i marken uden plantevækst eller store områder med meget ukrudt der adskiller sig i farve fra resten af marken, figur 7.



Figur 7. Marker fra Planet (3 x 3 m). Hvor grønne områder formentligt er ukrudt og lyse områder er lejesæd.

Derfor blev det besluttet at udvide træningsdatasættet med flere validerede marker med og uden lejesæd som indeholder lejesæd, og specifikt marker også med disse farveforskelle som ikke er til stede i det nuværende træningsdatasæt fra 2019.

Træning af forudsigelsesmodel

Da ground-truth af Planet.com billeder viste sig at være behæftet med usikkerhed, så blev der trænet en forudsigelsesmodel på blot markerne som er indeholdt i datasættet fra 2019 med Sentinel Hub (S2) data. Målet med forudsigelsesmodellen var at afsøge om forekomst af lejesæd på marken kort tid før høst kunne forudsiges ud fra satellitdata i hhv. februar og marts måned.

Tilgangen blev to særskilte modeller, hvor der i første model blev hentet S2 data så tæt på 1. marts som muligt baseret på tilgængelige skyfrie billeder over de vilkårlige marker og vice versa i anden model hvor data blev hentet så tæt på 1. april som muligt. Modellerne blev således trænet og testet ud fra næsten samme tilgang som detektionsmodellen. Resultaterne fra denne analyse viser at det måske ikke overraskende er betydeligt sværere at forudsige lejesæd lang tid før det optræder på marken, end at detektere det når det allerede er til stede på marken. Som det ses fra modellernes præstation på testsættet fra figurerne herunder, så er forudsigelsesmodellerne ikke meget bedre end tilfældige gæt begge med en accuracy på 63 %.

	precision	recall	f1-score	support
0	0.88	0.54	0.67	54419
1	0.45	0.84	0.59	24378
accuracy			0.63	78797
macro avg	0.67	0.69	0.63	78797
weighted avg	0.75	0.63	0.64	78797

Figur 8. Forudsigelsesmodel på testsæt med S2 data før 1. marts

	precision	recall	f1-score	support
0	0.84	0.57	0.68	54419
1	0.44	0.76	0.56	24378
accuracy			0.63	78797
macro avg	0.64	0.66	0.62	78797
weighted avg	0.72	0.63	0.64	78797

Figur 9. Forudsigelsesmodel på testsæt med S2 data før 1. april

Lejesædsforudsigelse viser er således ikke en helt enkel opgave med det begrænsede datasæt fra 2019, men kan muligvis forbedres via ground-truthing af et større valideret datasæt som træningsgrundlag for en detektionsmodel der kan håndtere større varians i farveforskelle på markerne. Fremtidige aktiviteter i lejesædsprojektet bør således fokusere på at forbedre det validerede datagrundlag som der foretages analyser på.

Validering af forudsigelsesmodel

Der er blevet lavet et tilfældigt udtræk af billeder for 2023 for marker der lå i de kategorier med lejesæd som er vist i tabel 2 og 3. Valideringen er sket på to måder. Dels ved at ringe til brugerne af de specifikke marker og spørge dem om der var lejesæd i marken i 2023. Dels ved visuel vurdering af lejesæd ud fra planet.com billederne, om der var lejesæd svarende til kategorien som modellerne var grupperet i. I tabel 2 og 3 ses resultatet af den visuelle vurdering af billederne. Modellen har vist sig at have en meget ringe præcision i kategorien med lejesæd på mellem 80-100 %, til gengæld har den en god præcision på marker med 0-20 % lejesæd. Da den største del af markerne ikke har lejesæd vil man også forvente at modellen derfor har nemmere ved at finde marker i kategorien uden lejesæd, og der er derfor ikke så store risiko for at fejle i denne vurdering.

Resultaterne for opringing til brugere at markerne viser at 43 % af markerne ligger i den rigtige kategori, tabel 4. Hvis man ser på marker hvor modellen har forudsagt mellem 40 – 100 % lejesæd har der været en præcision på 19 % (4 marker ud af 21). Den lave værdi bekræfter at modellen ikke er tilstrækkelige god.

Forudsigelsesmodellen for lejesæd skal forudsige hvor der er risiko for lejesæd på baggrund af biomassen i foråret. Efter dette tidspunkt kan både vejrforhold og management betyde at der ikke kommer lejesæd. I 2022 og 2023 forventes vejrforholdene med mangel på nedbør i foråret at have reduceret lejesædsrisikoen. Betydning af managementeffekt i form af forskellige indsatser (vækstregulering, reduceret kvælstof m.v.) er ikke muligt at vurdere ud fra det undersøgte datamateriale.

Hvor bliver der 80-100 procent lejesæd?	Sandt (%)	Falsk (%)
2023	0	100
2022	0	100
2019	32	68
Alle tre år	13 (6 observationer)	87 (41 observationer)

Tabel 2. Validering af forudsigelsesmodel på marker fra planet.com.

Hvor bliver der 0-20 procent lejesæd?	Sandt (%)	Falsk (%)
2023	100	0
2022	92	8
2019	93	7

Alle tre år	95 (35 observationer)	5 (2 observationer)
-------------	-----------------------	---------------------

Tabel 3. Validering af forudsigelsesmodel på marker fra planet.com.

Lejesædkategori	Sandt	Falsk
	Antal marker	Antal marker
80-100 procent lejesæd	1	7
60-80 procent lejesæd	1	5
40-60 procent lejesæd	2	5
0-20 procent lejesæd	9	0
I alt	13 (43%)	17 (57) %

Tabel 4. Validering af forudsigelsesmodel på marker fra planet.com. ved opringning til brugere