

# Kamerabaseret bestemmelse af sygdomstryk i sukkerroer med kunstig intelligens

Anders Krogh Mortensen, [anmo@ece.au.dk](mailto:anmo@ece.au.dk) og René Gislum, [rg@agro.au.dk](mailto:rg@agro.au.dk)

## Konklusion

Baseret på de foreløbige resultater opnået i dette projekt:

- Det er muligt at indsamle farvebilleder af sukkerroer med en markrobot i tilstrækkelig kvalitet til at et menneske kan genkende de gængse sygdomme rust, meldug og Cercospora-bladplet.
- Efter annotering af billederne er det muligt at træne et dybt neuralt netværk til at genkende sukkerroe, baggrund og sygdomme (rust og delvist meldug; Cercospora-bladplet var ikke tilgængeligt i testdata).
- Det er muligt at monitorere sygdomsudviklingen i sukkerroer over tid ved at analysere de indsamlede billeder med det trænede netværk.

## Conclusion

Based on the preliminary results achieved in this project:

- It is possible to collect colour images of sugar beet with a field robot in sufficient quality for a human to recognize the common diseases rust, mildew, and Cercospora leaf spot.
- After annotating the images, it is possible to train a deep neural network to recognize sugar beet leaves, background, and diseases (rust and partly mildew; Cercospora leaf spot was not present in test data).
- It is possible to monitor the development of the disease in sugar beet over time by analysing the collected images using the trained network.

## Formål

Formålet med forsøget er at undersøge, om et høj kvalitets farvekamera sammen med kunstig intelligens kan anvendes til automatisk genkendelse af sygdomme i sukkerroer.

## Metode

Tre sorter (Falster, Mango og Nasser) blev etableret på 50 cm rækkeafstand i et sribeforsøg i Flakkebjerg. De tre sorter blev smittet med meldug (*Erysiphe betae*), rust (*Uromyces beticola*) og Ramularia-bladplet (*Ramularia beticola*). Vejrforholdene var desværre ikke gunstige, efter roerne blev smittet, og de udviklede sygdomme på roerne er derfor primært naturligt udviklede sygdomme. Der er foretaget ugentlig dataindsamling med et specialbygget RGB kamera monteret på en markrobot. Efter vækstsæsonen er udvalgte billeder manuelt annoteret pixelvist, og et dybt neuralt netværk er trænet på baggrund af de udvalgte billeder til at genkende plante og sygdom.

## Dataindsamling

Stribeforsøget blev gennemført 9 gange (cirka ugentligt) fra midt juli til start september af Aarhus Universitet Flakkebjergs markrobot Robotti (AgroIntelli, Aarhus, Danmark). Et specialbygget 5 megapixel farvekamera med indbygget blitz var monteret i ca. 1 m højde over jorden på Robottis 3-punktsophæng (Figur 1) og gemte et billede for hver 1 m. Kameraet kiggede ned af og dækkede et synsfelt på 0,53m x 0,44 m på jorden med 4,6 pixels per mm. Over 22.000 billeder blev indsamlet i alt, svarende til 2.000-2.500 billeder for hver gennemkørsel inklusive billeder mellem rækkerne.

For at danne et varieret datamateriale til træning af det neurale netværk, blev 200 billeder tilfældigt udvalgt fra hver kørsel. I hver af disse billeder blev rektangulære interesseområder manuelt udpeget. Dette inkluderede både områder med og uden sygdom samt med og uden plante. I alt blev 1721 interesseområder udpeget på tværs af datoerne. I alt 32 interesseområder blev manuelt udvalgt på tværs af kørselsdatoerne, sygdomsgrad, og plantedække, således de bedst muligt repræsenterede variationen i marken. Efterfølgende blev de udvalgte interesseområder annoteret pixelvist efter de følgende 8 klasser: "Blad (friskt)", "Blad (vissent)", "Rust", "Meldug", "Bladplet (Ramularia)", "Bladplet (Cercospora)", "Sygdom (ukendt)", og "Andet" (f.eks. jord, ukrudt, o.l.). Under annoteringen blev det observeret, at spejlende refleksioner fra blitzten kan ligne meldug, som dog ofte er mere mat i udtrykket. I alt 31 af de annoterede interesseområder blev udvalgt til træningsdata og et blev udvalgt til testdata.

## Kunstig intelligens

Et dybt neuralt netværk af typen DeepLab V3+ med en Xception-65 backbone blev trænet til at lave pixelvis klassifikation af de indsamlede billeder. Da klassen "Bladplet (Ramularia)" ikke var repræsenteret i træningsdata, blev denne ekskluderet under træningen. Ligeledes var klasserne "Rust", "Bladplet (Cercospora)" og "Sygdom (ukendt)" kraftigt underrepræsenteret i træningsdataet. Disse klasser blev derfor vægtet ekstra højt under træningen.

Efter træning blev hvert af de indsamlede billeder analyseret af det trænede netværk ved tre forskellige skaleringer af original billedet. Til sidst blev resultatet fra hver skalering af et givent billede kombineret til en samlet analyse af billedet.

Særligt tak til Søren Kelstrup Skovsen (Institut for Elektro- og Computerteknologi, Aarhus Universitet) for hjælp til træning af det dybe neurale netværk.

## Resultater og diskussion

Det annoterede interesseområde fra testsættet blev efter træningen analyseret af netværket (Figur 2). En kvantitativ sammenligning mellem de manuelle klassifikationer og klassifikationerne udført af netværket ses i Tabel 1. Det ses her, at netværket er god til at genkende "Blad (friskt)", "Rust", og "Andet", hvor der er mindst 80% sammenfald mellem menneske og det neurale netværk. Fordelingen mellem de fem klasser i billedet er sammenlignelig for menneske og netværk, men netværket har dog en tendens til at overestimere mængde af rust og underestimere mængden af meldug. Overestimatet af rust vurderes til primært at komme fra et større areal omkring hver rust plet end et øget antal falske positive. Dette vil i fremtiden kunne tilpasses ved at justere på tærskel værdien for klassen. Underestimatet af meldug skyldes, at netværket ikke helt har lært at kende forskel på meldug og refleksioner. I fremtidigt arbejde kan refleksionerne tildeles sin egen klasse for at tvinge netværket til at kende forskel på de to klasser.



Figur 1. Dataindsamling i sukkerroer med markrobot. RGB kamera monteret på 3-punktsophæng. Foto: Tim Nellemann Bak.



Figur 2. Eksempel på automatisk pixel klassifikation. a) Input farvebillede. b) Klassifikationer lavet af det dybe neurale netværket. Grøn = blad. Gul = Rust. Lys blå = Meldug. Mørk blå = Andet.

Områder, som indeholder både meldug og rust, er desuden blevet annoteret som rust i trænings- og testdata. Det betyder, at disse områder vil være med til at underestimere den totale mængde meldug, om end størrelsen af fejlen er ukendt. Fremadrettet kan dette løses ved at lave et klassifikationsbillede per klasse frem for ét samlet klassifikationsbillede.

### Sygdomstryk over tid

Alle indsamlede billeder fra de fire parceller er blevet analyseret af det dybe neurale netværk. Derefter er rust sygdomstryk bestemt i hvert billede ved at tage antallet af pixels klassificeret som enten rust delt med antallet af pixels klassificeret som enten "Rust", "Meldug" eller "Blad (friskt)".

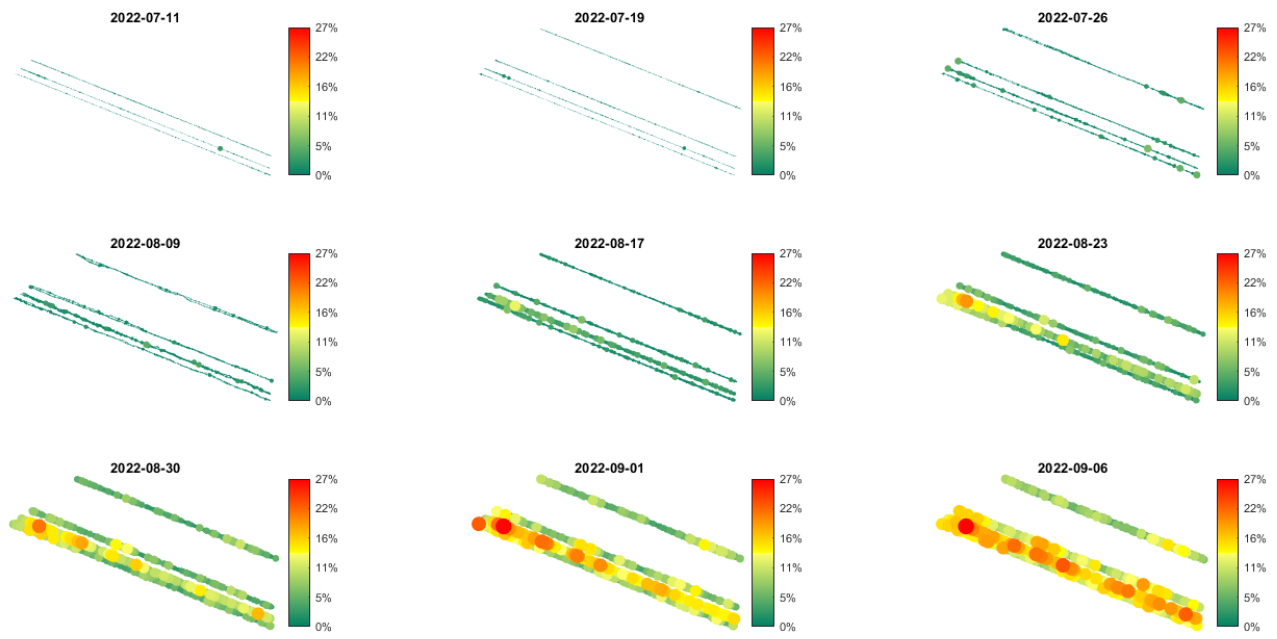
På Figur 3 ses udviklingen af rust i de fire parceller over tid. Det ses, at der

er spor af rust meget tidligt (2022-07-11) i den midterste af de tre nederste rækker, samt at disse områder udvikler sig over tid. Særligt i den øverste venstre del af den midterste række. Det ses desuden, at sygdom i højere grad udvikler sig langs rækken end på tværs af rækkerne.

På grund af forholdet mellem billedafstanden og kameraets synsfelt har det ikke været muligt at følge den enkelte plante over tid - kun ca. det samme område. I 2023 vil vi øge samplingsfrekvensen, så vi har et overlap mellem billederne, og dermed kan følge udviklingen af den enkelte plante over tid.

Tabel 1. Sammenhængen mellem pixel klassifikationer udført af menneske og kunstig intelligens.  $N = 1,4 \cdot 10^6$  pixels.

		Kunstig intelligens				
		Blad (friskt) 83%	Blad (vissent) 0%	Rust 7%	Meldug 6,6%	Andet 3,7%
Menneske	Blad (friskt) 84%	89%	0%	5%	5%	1%
	Blad (vissent) 0,5%	18%	0%	1%	0%	81%
	Rust 2,5%	18%	0%	80%	1%	0%
	Meldug 10%	65%	0%	6%	26%	2%
	Andet 2,3%	7%	0%	0%	0%	93%



Figur 3. Udvikling af rust over tid for de fire rækker. Hver cirkel repræsenterer sygdomstrykket fundet i et givent billede. Størrelsen og farven af cirklerne er proportionalt med sygdomstrykket. Længden af hver række er ca. 250-300 m.