



Circular AI AI og Machine Learning til closed- loop genanvendelse af plastemballage og fødevarekartoner MUDP-projekt

Udgiver: Miljøstyrelsen

Redaktion:
Lars Mensal

Fotos:
IHFood A/S

ISBN: 978-87-7038-723-1

Miljøstyrelsen offentliggør rapporter og indlæg vedrørende forsknings- og udviklingsprojekter inden for miljøsektoren, som er finansieret af Miljøstyrelsen. Det skal bemærkes, at en sådan offentliggørelse ikke nødvendigvis betyder, at det pågældende indlæg giver udtryk for Miljøstyrelsens synspunkter. Offentliggørelsen betyder imidlertid, at Miljøstyrelsen finder, at indholdet udgør et væsentligt indlæg i debatten omkring den danske miljøpolitik.

Må citeres med kildeangivelse.

Miljøteknologisk Udviklings- og Demonstrationsprogram

Projektet, som er beskrevet i denne rapport, er støttet af Miljøteknologisk Udviklings- og Demonstrationsprogram (MUDP) under Miljøministeriet, der støtter udvikling, test og demonstration af miljøteknologi.

MUDP investerer i udvikling af fremtidens miljøteknologi til gavn for klima og miljø i Danmark og globalt, samtidig med at dansk vækst og beskæftigelse styrkes. Programmet understøtter dels den bredere miljødagsorden, herunder rent vand, ren luft og sikker kemi, men understøtter også regeringens målsætninger inden for klima, biodiversitet og cirkulær økonomi.

Det er MUDP's bestyrelse, som beslutter, hvilke projekter der skal modtage tilskud. Bestyrelsen betjenes af MUDP-sekretariatet i Miljøstyrelsen.

MUDP-sekretariatet i Miljøstyrelsen
Tolderlundsvej 5, 5000 Odense | Tlf. +45 72 54 40 00

Mail: ecoinnovation@mst.dk
[MUDP's hjemmeside](#)

Denne slutrapport er godkendt af MUDP, men det er alene rapportens forfatter/projektlederen, som er ansvarlige for indholdet. Rapporten må citeres med kildeangivelse.

Indhold

1.	Indledning	6
1.1	Forord	6
2.	Arbejdspakke 1	8
2.1	Arbejdspakke 1: Studier	8
2.1.1	Feasibility-studie af detektion af logoer og genbrugssymboler	8
2.1.1.1	Objektdetektion	8
2.1.1.2	SIFT-baseret objektdetektion	8
2.1.1.3	SIFT Real-time implementation	8
2.1.2	Kortlægning af interessante plastemner og fødevarekartoner	8
2.1.2.1	Sorte fødevarebakker	9
2.1.2.2	Manuel sortering	9
2.1.2.3	Annotering	10
2.1.2.4	Resultat	10
2.2	Dialog med interessenter	10
2.2.1	PET-flasker	10
2.2.2	Fødevarekartoner	10
3.	Arbejdspakke 2: Udvikling af AI / Machine Learning-algoritmer	11
3.1	Udvikling af machine Vision systemer	11
3.1.1	Optagehardware	11
3.1.2	Udvikling af detektion- og sorteringsapplikation	12
3.1.3	Optagelse af billeder	13
3.1.3.1	Installation hos ARC	13
3.1.3.2	Installation hos Damifo, Vojens	13
3.1.4	Annotering af plastemner på indsamlede billeder	14
3.1.4.1	Klasser af sorte plastbakker	15
3.1.5	Annoteringsværktøj	17
3.1.5.1	Annotering via CVAT	18
3.1.5.2	Annoteringsguide version 0.5	18
3.1.5.3	Annoteringsguide version 0.5.1	20
3.1.5.4	Annoteringer til objekt detektion	21
3.1.6	Optimering ved hjælp af visualisering	21
3.1.7	Optimering via embedding visualisering	22
3.1.7.1	Embedding visualisering vha. neurale netværk	22
3.1.8	IHFood ViewAnnotator	24
3.1.8.1	Annotering for brug i ResNet-18	25
3.1.8.2	Annotering af fødevarekartoner	26
3.2	Sammensætning af multi-GPU-maskine	27
3.3	Udvikling af AI/Machine Learning-algoritme	29
3.4	Udvikling af AI/Machine Learning-algoritme	29
3.4.1	Model til detektion af plastikobjekter	29
3.4.2	YOLOv7	29
3.4.3	ResNet-18	30
3.4.4	Model til klassifikation af billeder med tomt bånd	30
3.5	Udvikling af feature matching- og Machine Learning-algoritme	30

3.5.1	Undersøgelse af feature matching af fødevarekartoner	30
3.5.2	Delkonklusion på feature matching af fødevarekartoner fra katalog	33
3.6	Resultater	34
3.6.1	Resultater for klassificering af sorte plastbakker på ARC	35
3.6.1.1	Fejlklassificering	38
3.6.2	Resultater for klassificering af sorte plastbakker, Damifo Vojens	40
3.6.2.1	Forskelle på sorte plastbakker hos ARC og Damifo Vojens	41
3.6.3	Resultater for klassificering af fødevarekartoner	42
3.7	Udvikling af algoritme til undersøgelse af kemisk sammensætning for plastprodukter	44
3.7.1	Undersøgelse af plastiksortering i NIR-spektrum	45
3.7.2	Undersøgelse af forskelligt farvede plastemner og baggrunde	47
3.7.3	Undersøgelse af fødevarekartoner i NIR-spektrum	50
3.7.4	Del-konklusion af undersøgelser i NIR-spektrum	51
4.	Arbejdspakke 3: Udvikling af closed-loop sorteringskoncept	52
4.1	Opstilling i laboratorie	52
4.1.1	Udvikling af mekanisk design	52
4.1.2	Procesoptimering	53
4.1.2.1	Procesoptimering Robot	53
4.1.2.2	Systemintegration og afprøvning i laboratorie	55
5.	Arbejdspakke 4: Afprøvning på testanlæg	57
5.1	Installation på testanlæg	57
5.2	Sugekop test på ARC	57
5.2.1	Test med 4 forskellige sugekopper på 100 styk sorte kødbakker	57
5.3	Test og optimering på testanlæg	59
6.	Arbejdspakke 5: Formidling	60
6.1	Formidling af resultater og fremtidig udnyttelse	60
6.1.1	IFAD München	60
7.	Konklusion	62
7.1	Konklusion	62
8.	Perspektivering	63
Bilag 1.	Bruger vejledning - Robot	64
Bilag 1.1	Bruger vejledning	64
Bilag 1.2	Emneliste	65
Bilag 1.3	Liste over virksomheder fra IFAT 2024	69

1. Indledning

1.1 Forord

Projektet "Circular AI" er støttet af Miljøteknologisk Udviklings- og Demonstrationsprogram (MUDP) under Miljø- og Ligestillingsministeriet, som har til formål at fremme udvikling og anvendelse af miljøeffektive løsninger på prioriterede miljøudfordringer og understøtte vækst og beskæftigelse.

Hvert år bliver der indsamlet 84.000 tons plastaffald i Danmark, men kun 42% af dette bliver genanvendt. Der er derfor langt til EU's mål om 65% genanvendelse i 2035. En af de store udfordringer er detektion og korrekt sortering af plast, herunder sort plast, hvilket især benyttes til fødevareplast samt plast til rengøring, personlig hygiejne og kosmetik. En undersøgelse fra DTU¹ viser, at fødevareplast udgør 52% af det plastaffald, der kildesorteres fra husholdninger i Københavns Kommune. Plast til rengøring, personlig hygiejne og kosmetik udgør 18% af plastaffaldet. Ydermere vil mange kommuner indsamle fødevarekartoner og plast i én fraktion.

En anden undersøgelse fra DTU² peger på, at de nuværende optiske sorteringssystemers manglende evne til at adskille forskellige produkttyper (flasker, bakker osv.) med forskellige anvendelser og design, udgør en primær hindring ift. at opnå closed-loop genbrug af plastemballage. Sort og mørk plast er en særlig udfordring for eksisterende optiske NIR-/MIR-sorteringssystemer, og de kan heller ikke skelne på anvendelse (fødevarer, ikke-fødevarer osv.), produkttype eller producent/brand/produkt.

Der er således et stort behov for AI- og sorteringssystemer, som kan detektere og udsortere fødevareplast og kosmetikplast separat – med en så høj grad af renhed at det kan genanvendes i et lukket kredsløb – og systemer, som samtidig kan håndtere sort og mørk plast.

Dette MUDP-projekt har til formål at videreudvikle IHFoods AI- og robotsystem, som er i stand til at identificere plastobjekter efter anvendelse og produkttype – også sorte og mørke plastobjekter. Dette vil styrke cirkulære processer indenfor affaldshåndtering. Ved hjælp af state-of-the-art computer vision-algoritmer, bygget på neurale netværk (Deep Learning/AI), vil IHFood i dette projekt, optimere algoritmer og robotteknologi samt validere løsningen gennem test i samarbejde med ARC og Damifo Vojens A/S således at plastaffaldet kan genanvendes i lukkede kredsløb. Et system forventes som minimum at kunne detektere og sortere 520 tons plast affald om året, svarende til 1060 tons CO₂e-besparelse, og dermed øge genanvendelse og genbrug af plast.

Selvom NIR-teknologi generelt har udfordringer med at detektere sorte eller mørke plasttyper, såsom sorte kødbakker, kan IHFoods udviklede løsning, kan supplere og forbedre NIR-systemernes effektivitet. Carbon, som ofte tilsættes sorte plastmaterialer for at opnå farven, absorberer størstedelen af NIR-lyset, hvilket gør det næsten umuligt for NIR-teknologi alene at skelne mellem forskellige plasttyper.

IHFoods teknologi benytter et kamera, der arbejder sammen med maskinlæringsalgoritmer og computer vision for at forbedre genkendelsen af sorte plasttyper, især sorte kødbakker. Ved at anvende teknikker, der er velkendte fra ansigtsgenkendelse, og gennem et omfattende datasæt med tusindvis af billeder af sorte plastbakker under forskellige forhold, kan AI-systemet identificere forskelle i mønstre og teksturer, som NIR-teknologi ikke kan opfange alene.

Selvom vi ikke er bedre end NIR i sig selv, beviser vores undersøgelser, at når vores teknologi kombineres med NIR, opnås bedre resultater samlet set. Dette partnerskab mellem vores teknologi og NIR-spektroskopi muliggør en mere præcis sortering af sorte plasttyper, og systemet kan dermed effektivt øge genanvendelsesraten for disse materialer. I Danmark ender omkring

¹ Fredenslund et al., *Analyse af eftersortering af restaffald - Udsortering af plast og metal fra restaffald*, Miljøstyrelsen, Miljøprojekter No. 2109 (November 2019)

² Pivnenko et al., *Preliminary assessment of plastic material flows in Denmark - Technical report*. Miljøstyrelsen, Miljøprojekter No. 2090 (Juni 2019)

50% af plastaffaldet, herunder sort plast, i forbrænding, hvilket viser behovet for bedre sorteringsteknologier, der kan øge genanvendelsen. Denne samspilsbaserede teknologi bringer os et skridt tættere på de ambitiøse genanvendelsesmål sat af EU og repræsenterer en vigtig fremgang inden for cirkulær økonomi.

2. Arbejdspakke 1

Denne rapport redegør for aktiviteter i projektet fordelt på arbejdsplaner. Projektet har været opdelt i fem arbejdsplaner med tilhørende aktiviteter.

2.1 Arbejdspakke 1: Studier

Denne rapport redegør for aktiviteter i projektet fordelt på arbejdsplaner. Projektet har været opdelt i fem arbejdsplaner med tilhørende aktiviteter.

2.1.1 Feasibility-studie af detektion af logoer og genbrugssymboler

Logoer og symboler på forbrugeremballage kan bruges til at genkende og skelne mellem emballageprodukter, f.eks. vil Heinz- og Beauvais-logoer kunne bruges til at genkende og skelne mellem ketchupflaskeprodukter.

2.1.1.1 Objektdetektion

Logoer og symboler i et billede kan detekteres vha. objektdetektionsalgoritmer. Objektdetektion er en metode til at finde og identificere bestemte objekter i et digitalt billed- eller videosignal. Dette kan være brugbart i en række forskellige anvendelser, som f.eks. sikkerhedskameraer, bil- eller dronestyringssystemer og robotter.

Der findes flere forskellige metoder inden for objektdetektion, men de mest almindelige er i dag baseret på brugen af *convolutional neural networks* (CNN), som er en særlig udgave af et neuralt netværk. Et CNN er specielt designet til at genkende mønstre i billed- eller videosignaler. Dette gøres ved at træne netværket med et stort antal billedeksempler, hvilket gør det i stand til at genkende bestemte objekter. Objektdetektion med neurale netværk kræver et stort antal billedeksempler til træning, for at netværket kan lære at genkende objekterne. Grundet den store datamængde kan dette være tidskrævende.

2.1.1.2 SIFT-baseret objektdetektion

I modsætning til neurale netværk kræver objektdetektion med *Scale-Invariant Feature Transform* (SIFT) kun ét eksempelbillede for hvert objekt, der skal genkendes. Metoden finder unikke egenskaber i billedet kaldet "features" og kan genkende disse features, selv om billedet er blevet skaleret eller roteret.

En forudsætning for at kunne anvende SIFT-baseret objektdetektion er, at billedekvaliteten er tilstrækkelig høj, til at de nødvendige features (som kan være små detaljer) kan identificeres i billedet. For at opnå tilstrækkelig høj billedekvalitet er der valgt et kamerasystem, som producerer farvebilleder med en opløsning på 4 pixel/mm.

2.1.1.3 SIFT Real-time implementation

En simpel implementation af SIFT-baseret objektdetektion er for langsom til at kunne bruges til on-line-/robot-sortering af plastaffald, da en CPU-baseret (Central Processing Unit) SIFT skal bruge ca. 5 sekunder for at behandle ét billede, og der er behov for at kunne behandle flere billeder pr. sekund.

Ved at implementere SIFT-baseret objektdetektion på en måde, der muliggør, at mange SIFT-features behandles i parallel, kan beregningerne udføres af en GPU (Graphics Processing Unit) i stedet for en CPU. Dette gør det muligt at udføre SIFT-baseret objektdetektion på under 100 millisekunder pr. billede, svarende til 10 eller flere billeder i sekundet.

2.1.2 Kortlægning af interessante plastemner og fødevarekartoner

Interessante plastemner og fødevarekartoner er blevet kortlagt dels gennem en gennemgang af sorte fødevarebakker og dels gennem dialog med interessenter.

2.1.2.1 Sorte fødevarebakker

Med baggrund i de hidtidige resultater fra projektet var det ønskværdigt at opnå følgende mål:

1. Øge antallet af sorte fødevarebakker på billeder der anvendes til træning af Machine Learning-algoritmer.
2. Øge antallet af typer af sorte fødevarebakker der forsøges genkendt af Machine Learning-algoritmerne.

Dels for at øge den statistiske signifikans af resultaterne af træning af Machine Learning-algoritmer, og dels for at øge mængden af fødevarebakker der kan genkendes af Machine Learning-algoritmerne.

2.1.2.2 Manuel sortering

Med henblik på at opnå de ønskede mål blev der indsamlet en stor mængde sorte fødevarebakker på Københavns Kommunes testanlæg til plastsortering på ARC. Dernæst blev de manuelt sorteret, på gulvet på testanlægget, på baggrund af deres udseende i ca. 60 kategorier. I hver kategori var der alt fra ca. 10 til mange hundrede eksempler på hver fødevarebakke.



FIGUR 1. Manuel sortering af sorte fødevarebakker på gulvet på Københavns Kommunes testanlæg til plastsortering på ARC.

Endeligt blev der optaget billeder af alle fødevarebakkerne - én kategori ad gangen - ved at bruge robotsorteringsanlægget på testanlægget. Hver kategori blev optaget i to forskellige konfigurationer: En konfiguration hvor bakkerne lå med forsiden opad og én konfiguration hvor bakkerne lå med forsiden nedad. I alt blev der optaget ca. 3200 billeder.

Med henblik på at bruge de optagede billeder til træning af Machine Learning-algoritmer blev optagetidspunktet for hver kategori noteret i en tabel, samt noter om hvilken type fødevarebakke der var tale om. Robotsorteringsanlægget sørgede for at tidsstemple hvert billede.

2.1.2.3 Annotering

Sorte fødevarebakker (generisk) blev annoteret ved behandle billederne med detektor version 0.1.0 - som er trænet til at detektere denne specifikke type af fødevarebakker. Dernæst blev hver annoteringer tilføjet information om typen af fødebakke ved at sammenholde tabellen over optagetidspunkter med de tidsstemplede og annoterede billeder. Endeligt blev annoteringerne gennemgået ved at visualisere embeddings for et neuralt netværk.

2.1.2.4 Resultat

Resultatet af den manuelle sortering og efterfølgende annotering af sorte fødevarebakker var et datasæt bestående af ca. 3200 billeder af ca. 3600 sorte fødevarebakker annoteret ift. ca. 60 typer af sorte fødevarebakker.

Dette datasæt tjener et antal formål:

1. Kortlægning af typer af sorte fødevarebakker der er relevante at kunne genkende.
2. Test-sæt for test/evaluering af Machine Learning-algoritmer: Datasættet indeholder et signifikant antal af hver type fødevarebakke, og der er derfor mulighed for at teste Machine Learning-algoritmer på en statistisk signifikant mængde data.
3. Trænings-sæt for Machine Learning-algoritmer: På sigt kan datasættet i stedet benyttes som trænings-sæt - når dets rolle som test-sæt kan erstattes af andre datasæt.

2.2 Dialog med interessenter

I dialog med Damifo Vojens samt Prounit Frames er det blevet klart at der er en række typer af plastemner der er interessante at kunne genkende.

2.2.1 PET-flasker

På trods af pant-systemet for plast-flasker i Danmark (Dansk Retursystem) er der fortsat et væsentligt antal flasker i de strømme der behandles - f.eks. hos Damifo Vojens, hvor et stort antal flasker (uden pant) behandles. PET-flaskerne kan udsorteres med en væsentlig værdi for Damifo Vojens - og dertil er det også ønskværdigt at de ekskluderes fra de strømme der sendes videre til eksempelvis pyrolyse.

2.2.2 Fødevarekartoner

Fødevarekartoner kan genanvendes af virksomheder såsom Prounit Frames - særligt hvis fødevarekartoner der indeholder en aluminium-barriere kan skelnes fra fødevarekartoner der ikke indeholder en aluminium-barriere. Genkendelse af emballage med computer vision har en særlig fordel i denne henseende og det er derfor ønskværdigt at kunne genkende fødevarekartoner med og uden aluminium-barriere.

Affaldsbehandlingsvirksomheder som Damifo Vojens har yderligere en interesse i at kunne udsortere fødevarekartoner - dels for at kunne behandle dem med henblik på genanvendelse, men også med henblik på at kunne ekskludere dem fra de strømme der sendes videre til pyrolyse.

3. Arbejdspakke 2: Udvikling af AI / Machine Learning-algoritmer

3.1 Udvikling af machine Vision systemer

Det udviklede Machine Vision systemet består af lys, et kamera, en computer og en flexpicker. Kameraet føder billeder til computeren, hvorpå den udviklede IHFood Base applikation behandler billedet og sender kommandoer til robotten. Systemet integreres på anlægget, så lys, kamera og flexpicker er placeret over båndet, som affaldsstrømmen transporteres på. I affaldsstrømmens kørselsretning sidder først lys og kamera, dernæst flexpicker - der må tage billeder af affaldet, som computeren skal processere, før Flexpicker kan tage sig af det.

Alt dette er muligt, hvis man har en Software-applikation, som håndterer kamera(er), lys, bånd og robot(ter) samt selve billedbehandlingen. IHFood har udviklet en sådan Base applikation, som er fleksibel og kan tilrettes forskellige applikationer. Det gælder også i forhold til genkendelse af emner til recycling så som plastic-bakker eller -kartoner.'

Base Software-applikationen interfacer ikke alene til vision hardware som nævnt, men også til maskiner og PLC'er, og den styrer billedbehandlingen og holder styr på emner / objekter både i tid og rum.

Den kan optage billeder af specifikke objekter baseret på specifikke modeller eller filtre, så man kan fintune AI modelleringen. Endelig er der udviklet flere annoteringsværktøjer med views, som har bidraget til udviklingen af dette machine vision system. Slutteligt er Base Applikationens model anvendt til fejlanalyse.

3.1.1 Optagehardware

Systemet bruger følgende kamera- og lysudstyr:

- JAI GOX-12401C-PGE, 12 MP kamera
- Fujinon CF25ZA-1S, 25 mm linse
- 2x lysbars, 107 cm, hvidt lys


Kameraet har en sensorstørrelse på 4096x3000 pixels. Det er placeret i en højde over båndet, så opløsningen bliver 4 px/mm. Dermed dækker det 100 cm på tværs af båndet og 75 cm langs båndet.

Lyset er nødvendigt for at få mindst muligt variation mellem billederne - på denne måde er det nemmere for system at genkende relevante plastemner, da de belysningen altid vil være den samme. Uden lyset vil fx mængden af sollys kunne gøre, at to ens bakker ikke ligner hinanden tilstrækkeligt til, at systemet kan kende dem begge. For ikke at genere arbejderne omkring transportbåndet må lyset ikke blinke set med menneskeøjne. For at undgå udtværede billeder skal kameraet dog have meget kort eksponeringstid, og der må derfor bruges kraftig lys. Da det er dyrt og generende at have meget kraftig lys over båndet, er lyset lavet, så det konstant blinker med 100 Hz. Ved så høj frekvens opfattes lyset ikke kraftigt (af mennesker), men der er stadig lys nok til billedoptagelsen.

IHFood Base applikation software håndterer hele processen således at billedoptagelsen er synkroniseret med lyset. Base softwaren styrer timing-controlleren, der er koblet til transportbåndet, kameraet og lyset. Når det er tid til at tage et billede, sørger IHFood Base applikationen for at trigge kameraet samtidig med et blink fra lyset.

IHFood Base applikationen styring af timing-controlleren er essentiel i vores elektroniske systemer, for at sikre, at signaler og operationer er synkroniserede og forekommer på det rigtige tidspunkt.

Robotten modtager også enkodersignalet fra transportbåndet, der informerer om båndets bevægelse, da denne skal være synkroniseret med resten af systemet. Når IHFood Base applikationen beder robotten om at samle et emne op, arbejder de altså i samme koordinatsystem.




FIGUR 2. Flowdiagram over flowet i IHFood Base applikationen optagelseshardware.

3.1.2 Udvikling af detektion- og sorteringsapplikation

IHFood Base applikationen er udviklet i C#, som modtager billeder fra kameraet og sender sorteringskommandoer til en flexpicker, når billederne er analyseret. Billedoptagelsen er synkroniseret med transportbåndet, så der tages et nyt billede, hver gang båndet har flyttet sig 35 cm. Kameraets synsvinkel dækker 75 cm i båndets retning, så der vil naturligvis være et overlap mellem to billeder taget lige efter hinanden. Dette overlap er med til at sikre, at der optages et godt billede af alle plastikemner, altså hvor hele emnet optræder. Uden overlappet risikerer man, at nogle plastikemner kun optræder delvist, fordi snittet mellem to billeder kan ligge hen over emnet.

Alle billeder analyseres for at finde plastikemner, der skal udsorteres. Hvis et sådan emne detekteres, sendes der en kommando til robotten med opsamlings- og udsorteringskoordinater. Udsorteringskategorierne er konfigurerbare, så det er let at tilføje en ekstra udsorteringsspand eller ændre på hvilke plastikbakker, der skal i hvilken spand.

På grund af overlappet mellem billederne (beskrevet ovenfor) optræder de samme emner på flere billeder. For at undgå, at robotten forsøger at samle det samme emne op flere gange, holder IHFood's Base applikationen styr på de detekterede emner, så det bliver ignoreret i de næste billeder.



FIGUR 3. Skærbillede af PlasticWasteSorter Applikationen.

3.1.3 Optagelse af billeder

Der er optaget billeder til træning af modellen (se screenshot 1). Disse er optaget fra to forskellige installationer, hos ARC København og Damifo Vojens. De to installationssteder er meget forskellige hvilket er med til at sikre en god variation i de optagede billeder.

IHFood Applikationen indeholder en funktion til at gemme billede til disk. Disse billeder bruges til at træne modellen. Ved at benyttes de præliminære resultater fra tidlige udgaver af modellen kan billedoptagelsen indsnævres så datamængden begrænses.

Der er optaget hhv. 10259 og 8420 billeder til træning hos ARC i København og Damifo i Vojens. Billederne er optaget med vision-systemet gennem applikationen, som har funktionalitet til at gemme billederne på harddisken til fx træning af ny Machine Learning (ML)-model. Der er så vidt muligt forsøgt at optage på aftalte tidspunkter, hvor båndet har kørt med affald på. Dette er for at undgå at opsamle en masse ens og/eller "tomme" billeder (billeder uden plastemner). I løbet af projektet er der blevet udviklet funktionalitet til at undgå at optage tomme billeder.

I løbet af projektet er der optaget følgende antal billeder af affaldsstrømmen:

- ARC: 26453 billeder
- Damifo: 18246 billeder

3.1.3.1 Installation hos ARC

Hos ARC (se FIGUR 4) blev systemet og en sorteringsrobot installeret. Det er placeret umiddelbart før hvor affaldsstrømmen bliver taget ind på rullebåndet.



FIGUR 4. Sorteringsrobotten hos ARC set fra siden og forfra.

Det er først ved NIR sorteringsmaskinen at båndet bliver rystet, så affaldsstrømmen adskilles. Det vil sige, at der hvor IHFood sorteringsrobotten sidder er der ofte flere lags affald, hvilket besværliggør både detektionen af objekterne og robotens opsamlingssevne.

3.1.3.2 Installation hos Damifo, Vojens

Hos Damifo (se FIGUR 5) blev systemet installeret den 28. juni 2022. Her er der ikke installeret en robot, da systemet benyttes udelukkende som optagestation. Det er placeret efter deres NIR sorteringsmaskine og tager billeder af det restplast, som ikke er blevet udsorteret.



FIGUR 5. Optagestationen hos Damifo Vojens set fra siden og oppe.

Affaldsstrømmen hos Damifo er væsentlig mere “beskidt” i forhold til ARC, da plasten har været komprimeret og opbevaret udendørs, inden det bliver sorteret.

3.1.4 Annotering af plastemner på indsamlede billeder

Det er valgt at annotere alle sorte kødbakker i følgende klasser:

- FaerchM2270
- FaerchTyp2
- FaerchDanishCrown
- HiltonFoods1
- Takeaway
- Knuste
- Tildækkede
- Andre

Kameraet optager billeder af hele båndet, hvoraf plastemnerne udgør et mindre areal. For at kunne genkende de ønskede plastemner, skal de først manuelt ses igennem i en proces der kaldes annotering. Annoteringen består af manuelt indtegnede kasser omkring de relevante emner og en manuelt angivet klasse ift. hvilken sort plastikbakke det er.

3.1.4.1 Klasser af sorte plastbakker

De forskellige anoterede plastemner beskrives med eksempler og deres kendetegn.

Færch M2270: sorte bakker med få store riller i bunden. Disse riller løber parallelt med siderne og hinanden. Meget store bakker af denne type kan have en flad, hævet sektion i midten. Rillerne er også "brudt" ved hvert kryds, hvilket er den vigtigste forskel i forhold til andre lignende bakker.



FIGUR 6. Færch M2270 fra katalog (øverst) og optaget i affaldsstrøm (nederst).

Færch Type 2: sorte bakker med mange små nitter på bunden og få større nitter spredt ud over overfladen. Bakken har også lange riller langs siderne, fra bunden til toppen.




FIGUR 7. Færch Type 2 fra katalog (øverst) og optaget i affaldsstrøm (nederst).

Færch Danish Crown: sorte bakker med buede riller langs bunden uden "brud" ved krydsene. Rillerne fortsætter op ad siderne på bakken. På nogle af bakkerne er der Danish Crown logoet nedstøbt. I midten af bakken er der et hævet fladt område formet som et afrundet kvadrat. Mod den ene af de korte sider af bakken, er der et yderligere hævet fladt område, hvor Danish Crown typisk sætter et varemærke stempel.



FIGUR 8. Færch Danish Crown fra katalog (venstre) og optaget i affaldsstrøm (højre).

Hilton Foods 1: sorte bakker med en reflekterende overflade, med et nedsænket cirkulært areal i midten. De ligner meget **Færch Danish Crown** bakker, eftersom de også har buede riller langs bunden uden "brud" ved krydserne.



FIGUR 9. Hilton Foods 1 (selvnavngivet) optaget i affaldsstrøm.

Takeaway: sorte bakker med en reflekterende overflade, med et hævet rektangulært areal i midten. Der er en eller flere cirkulære støbefejl på plastikken nær midten af bakkerne. Bakkerne er glatte uden andre signifikante karakteristika.



FIGUR 10. Takeaway (selvnavngivet) optaget i affaldsstrøm.

Other: sorte bakker, som ikke falder i en af de fem ovenstående kategorier.

Der er således kun annoteret sorte plastikbakker. Der er valgt netop denne opdeling, da de fem specifikke klasser har nok forekomster i billederne ift. resten af de sorte plastikbakker, til at modellen vil kunne lære at skille dem ad. Hvis en kategori har for få billedeksempler bliver den for svær at lære at genkende. Kategorien **Andre** består således af bakker, som ikke forekommer så ofte som dem i de fem andre kategorier.

3.1.5 Annoteringsværktøj


Billederne er i første omgang annoteret med annoteringsværktøjet CVAT. CVAT gør det muligt at annotere objekter med diverse attributter som farve og produkt. På den måde kan en overkategori "plastikbakke" specificeres som værende sort og eventuelt en af de specifikke klasser. Ud over det gør CVAT det nemt at dele annoteringsprocessen mellem flere personer, og der er "review"-funktionalitet til at give feedback.

3.1.5.1 Annotering via CVAT

For effektivt at kunne annotere billeder har vi anvendt et open source-værktøj kaldet CVAT. CVAT er en webbaseret applikation som kan bruges til både at annotere billeder og videoer. Dette gør det nemt og fleksibelt at bruge for vores annotører, da alt de har brug for at arbejde, er en computer med en webbrowser og en internetforbindelse.

I CVAT annoterer man et billede ad gangen ved at lave afgrænsningsboks omkring de emner som man er interesserede i. Når man laver en afgrænsningsboks, vælger man hvilken klasse den skal tilhøre som i vores tilfælde er forskellige plastemner som f.eks. en flaske eller plastikbakke. Man kan også sætte attributter for hver afgrænsningsboks, som f.eks. farve, gennemsigthed eller form. Dette gør det muligt at lave mere præcise annoteringer som indeholder mere information, hvilket kan være nyttigt for at træne en machine learning model.

De billeder der bliver uploadet til CVAT bliver først kørt igennem en præ-annotering ved hjælp af en machine learning model, så billederne er grovt annoteret når de bliver sendt ud til annotørerne. Dette gør det nemmere og hurtigere for annotørerne at annotere billeder, da nogle af annoteringerne er lavet for dem. Det kan dog ske at der er fejl i præ-annoteringen som annotørerne så skal rette.



FIGUR 11. Eksempel på CVAT-annotering.

Når en task er færdigannoteret og godkendt, kan annoteringerne hentes ned fra CVAT og derefter bruges til træning af machine learning modeller. Vi har ved hjælp af CVAT annoteret over 20000 billeder.

3.1.5.2 Annoteringsguide version 0.5

For at kunne håndtere et bredt udsnit af plastemner og fødevarekartoner har det været nødvendigt at udvikle en annoteringsguide, dvs. retningslinjer for hvorledes annoteringen skal foregå. For at have struktur på annoteringsguiden har det været en hjælp at strukturere kategorierne vha. et annoteringsskema.

Eftersom det er mennesker der skal foretage kategoriseringen, skal der være så få kategorier som muligt. Det er derudover en fordel hvis en annotør kun står overfor et valg mellem et begrænset antal kategorier - gerne under 10. For på samme tid at kunne håndtere et stort antal kategorier er derfor nødvendigt at indføre en hierarkisk struktur for kategorierne.

Kategorierne skal dække forbrugeremballage, og det indførte hierarki tager derfor udgangspunkt i taksonomier for forbrugerprodukter, som *Google Product Taxonomy*, der indeholder kategorier såsom:


- 2018 - Fødevarer, drikkevarer og tobak > Fødevarer > Krydderier og saucer > Ketchup

- 2126 - Fødevarer, drikkevarer og tobak > Fødevarer > Ingredienser til madlavning og bagning > Madlavningsolie
- 2628 - Fødevarer, drikkevarer og tobak > Drikkevarer > Sodavand
- 543615 - Sundhed og skønhed > Personlig pleje > Hårpleje > Shampoo og balsam > Shampoo

Samt FN's Statistics Divisions Classification of Individual Consumption According to Purpose (COICOP) 2018, der indeholder kategorier såsom:

- 01.1 Food > 01.1.9 Ready-made food and other food products n.e.c. (ND) > 01.1.9.3 Salt, condiments and sauces (ND) > Ketchup
- 01.1 Food > 01.1.5 Oils and fats (ND) > Cooking oil
- 01.2 Non-alcoholic beverages > 01.2.6 Soft drinks > Soda

På denne baggrund er der udviklet et hierarki med følgende overordnede struktur:



FIGUR 12. Skema over anoteringsgrupper i CVAT.

Som det ses, præsenteres man ved hvert skridt i beslutningstræet ikke for mere end 10 valgmuligheder hvorved det både teknisk og menneskeligt er muligt at kapere antallet af valgmuligheder.

3.1.5.3 Annoteringsguide version 0.5.1

Med udgangspunkt i kortlægningen af plastemner og fødevarekartoner var det nødvendigt at opdatere annoteringsskemaet mht. sorte fødevarebakker

- **Færch M2270**
- **Færch type 2**
- **Færch Danish Crown**

med de mange ekstra kategorier af sorte fødevarebakker, f.eks.:

- **Hilton Foods 1**
- **Takeaway**

Hvor **Hilton Foods 1** og **Takeaway** er egen opfundne navne for fødevarebakker som på den ene eller anden måde relaterer sig til de valgte navne; **Hilton Foods** er en fødevareproducent som bruger deres navn på emballagen - og **Takeaway** dækker over bakker der typisk anvendes til take away-retter.

3.1.5.4 Annoteringer til objekt detektion

For at kunne arbejde effektivt med annoterede billeder - og for at kunne integrere de nyeste forskningsresultater indenfor computer vision er der behov for et framework som kan håndtere annoterede billeder.

Når objekter på billeder annoteres, kan de annoteres på et væld af måder, f.eks. vha. en afgrænsningsboks - et rektangel som lige akkurat omfatter objektet, eller vha. en polygon - altså en trekant, en firkant eller lign. der på samme måde som en afgrænsningsboks omfatter objektet. Ligeledes kan objekter annoteres med en orienteret afgrænsningsboks - et rektangel som er drejet/vinklet ift. billedets koordinatsystem.

Alle de tre ovenfor nævnte annoteringsformer kan anvendes når man anvender annoteringsværktøjer som CVAT - og alle de tre nævnte annoteringsformer optræder i den samlede mængde af annoterede billeder som er indsamlet i forbindelse med dette projekt.

Machine learning refererer til en gren af kunstig intelligens, hvor computere er i stand til at lære og forbedre deres præstationer på opgaver uden at være eksplicit programmeret til hver enkelt opgave. I stedet lærer de fra data, mønstre og erfaringer for at træffe beslutninger eller udføre specifikke opgaver.

3.1.5.4.1 Vigtigheden af høj data-kvalitet

En Machine Learning model's egenskaber afhænger derfor i høj grad af kvaliteten af det datasæt der ligger til grund for algoritmen. Generelt er det anerkendt at jo mere data i høj kvalitet der ligger til grund for en Machine Learning-algoritme, jo bedre vil algoritmen blive. Det estimeres³, at for at halvere fejlraten ifm. træning af en Machine Learning-algoritme skal datasættet firedobles i størrelse.

Men jo mere data der skal annoteres, jo mere tidskrævende bliver det - både i forhold til den menneskelige indsats der skal til for at annotere den store mængde data, men også i forhold til den tid det tager at træne algoritmen - fordi hele datasættet må processeres for hver kørsel af træningsproceduren.

Derfor er det vigtigt at kunne optimere udviklingen af Machine Learning-algoritmer ved at optimere annoteringen af datasættet.

3.1.6 Optimering ved hjælp af visualisering

Hvis et billede-datasæt er annoteret med hensyn til flaske-objekter, er det vigtigt at alle flasker på de givne billeder er annoteret og at ingen andre objekter er annoteret som flasker.

I den forbindelse er det essentielt at kunne visualisere annoteringerne på en måde der gør det nemt at se om annoteringerne er korrekte. Men en udfordring kan være at der er tale om et så stort datasæt at det umuligt at gennemse alle billederne manuelt.

Ved at tage udgangspunkt i værktøjet FiftyOne og udvikle skræddersyede værktøjer til dette formål har det været muligt at visualisere annoteringerne på en måde der gør det muligt at gennemse det store datasæt på en effektiv måde. På den måde blev det klart at et stort antal billeder, der indgik i træningen af Machine Learning-algoritmen, var mangelfuldt annoteret.

³ Hestness et al., *Deep Learning Scaling is Predictable, Empirically*, arXiv preprint (2017)

3.1.7 Optimering via embedding visualisering

Når et datasæt når en vis størrelse, er det en ekstremt tidskrævende opgave at gennemse alle billederne manuelt. I stedet kan det være en fordel at visualisere datasættet på en måde der gør det muligt at grov-sortere i dataen og derved koncentrere sig om en delmængde af datasættet.


En metode der gør det muligt at fokusere på en delmængde af datasættet er ved at anvende det der kaldes embedding visualisering. Ved embedding visualisering benyttes en model (f.eks. en præ-trænet Machine Learning-model) til at projicere hvert billede i datasættet ned i et n-dimensionelt vektorrum, f.eks. et 2-dimensionelt koordinatsystem. På den måde koges hvert billede ned til ét punkt i et koordinatsystem. Så i stedet for en uoverskuelig mængde af billeder har man nu ét koordinatsystem hvor hvert punkt repræsenterer et af billederne i datasættet. Dette har den effekt at punkter i koordinatsystemet der ligger tæt på hinanden repræsenterer billeder der ligner hinanden - så billeder af sorte fødevarebakker vil være repræsenteret af punkter der ligger i én lille sky af punkter, mens billeder af Faxe Kondi-flasker vil være repræsenteret af en anden lille sky af punkter.

3.1.7.1 Embedding visualisering vha. neurale netværk

Ifm. embedding visualisering er det muligt at anvende et væld af forskellige algoritmer til at projicere billederne ned i et n-dimensionelt vektorrum.

Et antal forskellige metoder er blevet afprøvet - herunder forskellige konfigurationer af ResNet-modellen, samt CLIP-modellen. Det er blevet klart at ResNet-embeddings i højere grad afspejler hvad billederne *ligner* (se FIGUR 14), mens CLIP-embeddings i højere grad afspejler hvad billederne *indeholder* (se FIGUR 13).


Dvs. at ResNet-embeddings for en Coca-Cola-flaske og en Faxe Kondi-flaske vil være længere fra hinanden, mens CLIP-embeddings for en Coca-Cola-flaske og en Faxe Kondi-flaske vil være tættere på hinanden. En anden måde at sige det på er at CLIP-embeddings er mere *semantiske* end ResNet-embeddings - eller at CLIP-embeddings repræsenterer en mere abstrakt fortolkning af billedet end ResNet-embeddings.



FIGUR 13. Visualisering af CLIP embeddings for sorte fødevarebakker.

ResNet-modellen findes i forskellige konfigurationer med forskellige dybder af det neurale netværk, f.eks. et neuralt netværk med 18 lag, et med 50 lag eller et med 152 lag. Umiddelbart ville man forvente at et netværk med flere lag ville give en mere abstrakt repræsentation af billederne netværket præsenteres for. I praksis har det vist sig at for sorte fødevarebakker er der ikke så stor forskel på visualiseringerne og et ResNet med 50 havde den bedste repræsentation af billederne af sorte fødevarebakker.


Vha. embedding visualisering var det muligt at tilrette annoteringerne af sorte fødevarebakker - navnlig med hensyn til bakketyperne Faerch M2270 og Faerch type 2. Bakketyperne Faerch Danish Crown var desværre sværere at visualisere på en måde hvor den tilhørende punktsky lå klart adskilt fra de øvrige punktskyer.



FIGUR 14. Visualisering af ResNet 50 embeddings for sorte fødevarebakker.

3.1.8 IHFood ViewAnnotator

Som det ses i de foregående afsnit, er det meget svært at bruge visualisering og semiautomatiske værktøjer til at hjælpe annoteringen af de forskellige bakketyper. Samtidig kræver ResNet-18 også et andet dataformat end YOLOv7. Derfor valgte IHFood at bruge et internt udviklet værktøj til at manuelt finsortere de sorte plastikbakker. Det interne værktøj går under navnet *ViewAnnotator* og et screenshot kan ses i FIGUR 15.



FIGUR 15. Screenshot af IHFoods internt udviklede ViewAnnotator, som blev brugt til annotering i forbindelse med træning af ResNet-18.

Med ViewAnnotator kunne IHFood derved sørge for et data set med **FaerchType2**, **Faerch-DanishCrown**, **FaerchM2270**, **Occluded**, **Crushed** og **Other**. I alt resulterede det i 4197 billeder i det samlede data set. Fordeling af dette data kan ses i TABEL 1.

TABEL 1. Tabellen viser fordeling af data efter frasortering og oprydning af den semiautomatiske annotering brugt til træning af YOLOv7. Dette data er kun brugt til træning af ResNet-18.

Faerch	Faerch Danish Crown	Faerch M2270	Occluded	Crushed	Other
1079	641	700	779	431	567

Efter indledende træningskørsler gav ResNet-18 meget lovede resultater, som kan ses i TABEL 4. Efter disse resultater blev datasættet udvidet med to yderligere bakke typer; *Hilton-Foods1* og *Takeaway*. Udover tilføjelsen af de to nye klasser, som involverede at flytte nogle bakker fra *Other* til en af de nye klasser, blev der også tilføjet en smule ekstra data fra grænseområderne til nogle af de eksisterende klasser. Den resulterende fordeling af datasættet kan ses i TABEL 2.

TABEL 2. Tabellen viser fordeling af data efter tilføjelse af HiltonFoods1 og Takeaway. Dette data er kun brugt til træning af ResNet-18.

Faerch type 2	Faerch Danish Crown	Faerch M2270	Hilton Foods 1	Takeaway	Occluded	Crushed	Other
1103	635	721	301	601	768	476	467

3.1.8.1 Annotering for brug i ResNet-18

For at kunne bruge billederne fra YOLOv7 data sættet til at træne en ResNet-18 model skal sættet konverteres til et format som ResNet-18 kan forstå, hvilket gjorde at IHFood brugte den interne ViewAnnotator, til at rette alle de relevante annoteringer.

Re-annoteringen af billederne forgik efter nogle simple regler

1. Mere end 1/3 af bakken skal være synlig, ellers markeres en bakke som **Occluded**

2. Hvis en bakke er knust i sådan en grad at et menneske ikke kan genkende bakketypen, markeres bakken som **Crushed**
3. Hvis det ikke er en af de 5 hovedkasser af bakker, markeres bakken som **Other**

Disse regler betyder at alle bakker som kan genkendes af et menneske vil blive inkluderet i træning, validering og i test af en ResNet-18 model. Men også at affaldsstrømmen bliver nødt til at være spredt ud så ikke mere end 2/3 af en bakke er dækket af noget andet affald. Disse begrænsninger er valgt for at kunne være sikker på at en bakke kan genkendes korrekt - og ellers skal en model placere billedet i en af de 3 ekstra klasser **Occluded**, **Crushed**, eller **Other**. For ikke at have et meget skævt dataset med mange bakker i **Occluded** eller **Other**, har IHFood udvalgt en repræsentativt udsnit af denne type billeder. Dette er gjort, fordi en model får sværere ved at lære flere unikke klasser, hvis en eller to klasser har et signifikant flere data punkter at træne på.

3.1.8.2 Annotering af fødevarekartoner

I Sektion 2.2.2 blev det kortlagt, at der er en interesse fra Damifo Vojens i at kunne adskille fødevarekartoner der indeholder en aluminium-barriere fra fødevarekartoner der ikke indeholder en aluminium-barriere.

For at indsamle data af fødevarekartoner, blev samtlige billeder optaget hos Damifo manuelt annoteret af eksterne annotører i programmet CVAT. For at kunne inspicere hver fødevarekarton individuelt, klippede vi disse billeder ud fra de indtegnede kasser og gemte billederne separat. Dette resulterede i 5673 usorterede fødevarekartoner.

Disse billeder blev dernæst manuelt annoteret i de følgende klasser:

- **FoodCartonAcidic** (Juice, nektar, saft, iste osv. på tværs af producenter og lande), hvoraf der er 333 billeder. Se FIGUR 16.



FIGUR 16. Eksempler på FoodCartonAcidic fødevarekartoner.

- **FoodCartonNonAcidic** (Mælk, yoghurt, kærnemælk, koldskål osv. på tværs af producenter og lande), hvoraf der er 1466 billeder. Se FIGUR 17.



FIGUR 17. Eksempler på FoodCartonNonAcidic fødevarekartoner.

Båndet er beskidt, hvilket ofte smitter af på kartonerne og ændrer udseendet på kartonerne drastisk. I annoteringsprocessen af fødevarekartonerne, er mange af de ekstremt beskidte fødevarekartoner derfor blevet frasorteret, eftersom de var umulige for annotørerne at klassificere selv.

Som det var tilfældet for sorte bakker, er der i affaldsstrømmen mange objekter, som ikke nødvendigvis ligger pænt adskilte i et lag. Derfor kan andre objekter ligge delvist ind over en fødevarekarton og gøre detektionsopgaven besværlig. Hvis en karton blev overskygget med mere end 1/2 af dens areal, blev den ikke inkluderet.

Hvis flere end en fødevarekarton var synlig på et billede, blev det billede ikke inkluderet, eftersom det vil være uklart hvilken fødevarekarton der bliver klassificeret.

3.2 Sammensætning af multi-GPU-maskine

Machine learning modeller kan være meget komplekse og kræve meget regnekraft. Derfor kan det være en kæmpe fordel at have en kraftig computer til at træne modellerne, da dette kan sænke træningstiden drastisk. Machine learning modeller kan med fordel gøre brug af kraftige GPU'er, da de i de fleste tilfælde er meget hurtigere end CPU'er til at træne modeller.

Til dette formål har vi valgt at bygge en maskine med 4 GPU'er, dette har en del fordele. Først og fremmest er det mere fleksibelt at have flere GPU'er, da man kan vælge mellem at træne 4 modeller på en gang som bruger en GPU hver, eller f.eks. bruge alle GPU'er på en gang til at træne en model meget hurtigt. Udover fleksibilitet, så stiger prisen på GPU'er eksponentielt i forhold til deres ydelse, så det er billigere at købe 4 kraftige GPU'er end at købe en enkelt meget kraftig GPU.

Vores maskine består af 4 Nvidia RTX 4090 GPU'er, se FIGUR 18, som på tidspunktet for udvikling var den hurtigste forbruger-GPU på markedet, med et tilsvarende højt energiforbrug. Man kunne også have valgt en Workstation GPU som er mindre i fysisk størrelse og som trækker mindre strøm, men til gengæld kommer man til at betale i hvert fald dobbelt pris for ca. samme ydeevne.



FIGUR 18. Multi-GPU-maskinen (øverst) og Multi-GPU-maskinen hvor den ene GPU er fjernet, så man kan se det bagvedliggende PCIe riser kort (nederst).

Der var nogle komplikationer undervejs da vi byggede maskinen på grund af RTX 4090'ernes størrelse, da de er meget lange og brede. Dette betød at de ikke kunne sidde i samme maskine hvis vi bare satte dem direkte ned i bundkortets PCIe slots. Derfor købte vi 4 PCIe riser kort, så vi kunne flytte GPU'erne så de ikke sad direkte i bundkortet.

Udover størrelsen på GPU'erne så er deres høje energiforbrug også lidt problematisk, da de trækker 450W hver når de kører på højest ydeevne. Med 4 GPU'er der kan trække 450W, er man allerede oppe på 1800W, og det er uden at tage CPU og alle de andre komponenter i betragtning. Det er svært at få en strømforsyning med mere end 2000W som passer ind i maskinen, og 2 strømforsyninger i samme maskine er ikke noget vi har erfaring med. Vi tjekkede derfor hvor meget ydeevne man ville miste hvis man kørte GPU'erne med en 300W grænse. Ændringen i ydeevne var meget lille så vi har valgt at køre med en 300W grænse på hver GPU.

TABEL 3 viser ydeevnen for GPU'erne ved forskellige strømforbrug og antal GPU'er ved træning af forskellige machine learning modeller. Som man kan se, er ændringen i ydeevnen minimal når man går fra 450W til 300W. Vi kunne desværre ikke teste med 4 GPU'er ved 450W da det var for risikabelt med en 2000W strømforsyning.

TABEL 3. Oversigt over ydeevnen for GPU'erne.

GPU/Mo- del	Watt	RestNet50	Ssd	Bert Base Finetune	Transfor- mation XL Larget	Tacetrone	NCF
2*4090 300W	600	2476	7280	539	77245	59161	67745432
2*4090 450W	9600	2513	568	568	79912	61165	69060512
S2*4090 300W	900	3583	773	780	-	-	-

GPU/Model	Watt	ResNet50	Ssd	Bert Base Finetune	Transformation XL Target	Tacotron	NCF
3*4090 300W	-	-	-	-	116222	90315	97038467
3*4090 450W	1350	3586	1066	780	119211	88425	96534322
4*4090 300W	1200	4746	894	1008	154391	107694	144037091

Samtlige modeltræninger i projektets løbetid er blevet trænet på Multi-GPU-maskinen.

3.3 Udvikling af AI/Machine Learning-algoritme

Til detektion af sorte fødevarebakker er der trænet en model baseret på YOLOv7 (YouOnly-LookOnce) netværket. Der er også udviklet en model til at detektere hvornår transportbåndet er tomt. Denne model benyttes til automatisk at frasortere tomme billeder når der skal optages data til træning af detektionsmodellen.

Der er udviklet en række machine learning (ML)-modeller både til detektion af plastemner og til at genkende et tomt affaldsbånd. En ML-model er resultatet af et datasæt af annoterede billeder og en algoritme, der kan lære at klassificere/kategorisere enten hele billeder eller objekter i billederne.

3.4 Udvikling af AI/Machine Learning-algoritme

Til detektion af sorte fødevarebakker er der trænet en model baseret på YOLOv7 (YouOnly-LookOnce) netværket. Der er også udviklet en model til at detektere hvornår transportbåndet er tomt. Denne model benyttes til automatisk at frasortere tomme billeder når der skal optages data til træning af detektionsmodellen.

Der er udviklet en række machine learning (ML)-modeller både til detektion af plastemner og til at genkende et tomt affaldsbånd. En ML-model er resultatet af et datasæt af annoterede billeder og en algoritme, der kan lære at klassificere/kategorisere enten hele billeder eller objekter i billederne.

3.4.1 Model til detektion af plastikobjekter

Modellen til detektion af sorte plastikbakker bygger oven på en eksisterende, generelle objekt-detektionsmodel kaldet YOLOv7. Der er i projektet arbejdet med YOLOv3, YOLOv4, YOLOv5, YOLOv7 og ResNet-18.

3.4.2 YOLOv7

Til detektion af plastikemner er der udviklet en ML-model baseret på YOLOv7, som er en generel objekt-detektionsmodel, dvs. den er trænet til at detektere objekter fra hverdagssituationer som fx mennesker, biler, m.m. Disse objekter har alle nogle fælles træk som fx kanter og skygger, og denne viden bygges der så oven på i vores model til detektion af plastikemner. Der udvikles hele tiden nye objekt-detektionsmodeller som YOLOv7, men særligt for denne er dens høje præcision og hurtige eksekveringstid sammenlignet med andre modeller - ud over dette er den også veldokumenteret og nem at bygge videre på. Fordelen ved at bygge videre på en eksisterende model (dette kaldes *transfer learning*) er, at træningstiden, altså den tid, som modellen bruger på at lære af eksempel-billederne, bliver markant kortere.

Modellen, som bygger på YOLOv7, fødes med en masse billeder af et transportbånd med affald, hvori de relevante emner er annoteret, og modellen lærer så de genkender disse emner, så den kan fortælle robotten, hvad den skal samle op, og således kan systemet sortere emnerne. Modellen er trænet på 6826 billeder med en fordeling svarende til en almindelig affaldsstrøm fra det pågældende sorteringsanlæg.

3.4.3 ResNet-18

ResNet-18 er en type dyb convolutional neuralt netværk, der er en del af familien af residual networks (ResNets). Det er designet til at tackle udfordringerne ved at træne dybe neurale netværk. Den unikke funktion ved ResNet-18 er brugen af residual blocks, som tillader gradienter at flyde gennem netværket uden at forsvinde, hvilket gør det muligt at træne dybere modeller effektivt. En dybere model er oftest bedre til at differentiere mellem små forskelle på bage karakteristika. Ligesom YOLOv7 er ResNet-18 også trænet på en lang række dyr og dagligdags objekter. Denne prætrænede model kan så fin-tunes til projektets data, hvorved man opnår en høj præstation med en relativ kort træningstid, og med langt færre billeder, end hvis man skulle træne en model fra ny.

ResNet-18 modellen bliver givet 5077 billeder af bakker optaget på Amager Ressource Center (ARC) til træning.

3.4.4 Model til klassifikation af billeder med tomt bånd

For at gøre annoteringsarbejdet lettere er der blevet udviklet en model, som kan afgøre, om et billede er tomt (altså kun viser affaldsbåndet) eller et eller flere emner (enten plast eller andet affald). Modellen er trænet på ca. 6000 billeder, hvor den ene halvdel er tomme, og den anden halvdel indeholder et varierende antal emner i forskellig størrelse. Billederne er markeret som enten værende tomme eller ej, og modellen har derfor lært at klassificere billeder som værende tomme/ikke-tomme med 99,7% præcision testet på 748 billeder. På samme måde som med objekt-detekektionsmodellen bygger denne model også videre på en anden, mere generel model. I dette tilfælde ResNet. Ved at bruge denne model under optagelse af billeder undgås det derfor, at tomme billeder forstyrrer annoteringsprocessen, og kvaliteten af datasæt bliver større. Modellen er trænet på billeder fra ARC, men fungerer også godt på billeder hos Damifo. Man må gå ud fra, en ny model med billeder fra Damifo vil fungere bedre. Dette kræver blot et datasæt fra Damifo lig det fra ARC, og så kan en ny træningsproces sættes i gang.

3.5 Udvikling af feature matching- og Machine Learning-algoritme

Vedr. Feature matching og machine learning-algoritmer skal der indsamles meget data hvorefter der udtrækkes interessante punkter, teksturer og forme fra emnerne, på hvert billede. Feature matching matcher de udtrukket egenskaber fra to eller flere billeder ved at sammenligne deres ligheder og forskelle.

Man tester modellen på separat testdatasæt og evaluerer dens nøjagtighed ved hjælp af metoder som f.eks. confusion matrix, precision, recall og F1-score. Derefter forbedres modellen ved at justere dens parametre og opdatere træningsdatasættet, hvis det er nødvendigt, indtil den når den ønskede nøjagtighed.

Feature matching er en teknologi IHFood har erfaring med fra andre applikationer. Eksempelvis ved at matche afskårede dele af grise til grise ud fra SIFT feature matching af stempler. Derfor har vi en klar forventning om, at feature matching kan indføres ift. at matche etiketter på fødevarekartoner med etiketter i et katalog, dog med forbehold for særdeles beskidte, knuste eller tildækkede fødevarekartoner, hvor etiketten ikke kan ses.

3.5.1 Undersøgelse af feature matching af fødevarekartoner


For at undersøge dette vil det første skridt være at indsamle et fyldestgørende datasæt af fødevarekartonetiketter og annotere tilsvarende fødevarekartoner fra en affaldsstrøm. I løbet af projektet, har arbejdet med at udvikle en Machine Learning model ift. klassifikation af sorte bakker været vægtet højere og der er derfor ikke foretaget en større undersøgelse mhp. konkrete resultater for feature matching.

I stedet, vises nogle eksempler på matchede fødevarekartoner på FIGUR 19 til FIGUR 22. De matchede features er fundet vha. en præ-trænet feature matching model kaldet *xFeat*⁴, udviklet af VeRLab. Figurerne viser to versioner af en fødevarekarton – en referenceversion (til venstre), hentet fra producenten *Thise* eller *Rynkeby's* hjemmeside, og en version fundet i affaldsstrømmen fra Damifo Vojens(til højre). De grønne linjer og rektangler på billedet er resultatet


af en proces, hvor der er blevet matchet specifikke, karakteristiske punkter på de to versioner af kartonen.

- **Grønne streger:** De grønne streger viser, hvor *xFeat* har fundet tilsvarende punkter på referencekartonen og kartonen fra affaldet. Disse punkter (også kaldet "features") kan være genkendelige detaljer som logoer, tekst eller mønstre, der ser ens ud på begge billeder.
- **Grøn rektangel:** Det grønne rektangel, der er tegnet rundt om kartonen i affaldet, viser den projicerede omrids af referencekartonen. Dette rektangel viser, hvordan referencekartonen ville se ud, hvis den blev "warp'et" (deformeret eller tilpasset) til affaldsbilledet, baseret på de matchede punkter.

Feature matchingen i tilfælde hvor kartonen i affaldsstrømmen er orienteret i en anden retning end reference-kartonen fra kataloget og knuste/krøllede kartoner kan ses på FIGUR 23.



FIGUR 19. Eksempler på feature matching af [Thise Änglamark Minimælk kartoner](#).



FIGUR 20. Eksempler på feature matching af Thise 365 Øko Letmælk kartoner⁵.




FIGUR 21. Eksempler på feature matching af Rynkeby 16 Søde Appelsiner kartoner⁶.

⁵ [Kilde.](#)

⁶ [Kilde.](#)



FIGUR 22. Eksempler på feature matching af Rynkeby Blandet Saft kartoner.



FIGUR 23. Eksempler på svære kartoner at feature matche.

3.5.2 Delkonklusion på feature matching af fødevarekartoner fra katalog

En kort undersøgelse med feature matching mellem referencekartoner og affaldskartoner har demonstreret potentialet for at identificere specifikke fødevarekartoner i affaldsstrømmen, ud fra en enkelt referencekarton ved hjælp af en præ-trænet model som *xFeat*. Undersøgelsen skal ikke opfattes som fyldestgørende, men det er en indikation på at man i praksis kunne bruge feature matching til at identificere fødevarekartoner.


Et potentielt scenarie, er at opstille en database af referencekartoner, der opdateres kontinuerligt, når producenter opdaterer designet på deres fødevarekartoner. Denne database kunne tilgås ift. feature matching for hver detekteret fødevarekarton i affaldsstrømmen og bruges til at klassificere dem, uden behov for at træne en ny model.

Resultaterne viser, at *xFeat* kan genkende features på en række kartoner, selv når de er let beskadigede, krøllede eller tildækkede.

3.6 Resultater

I dette afsnit præsenteres resultaterne fra klassifikation af sorte fødevarebakker og fødevarekartoner fra vores tests på Amager Ressource Center (ARC) og Damifo Vojens.

FIGUR 24 og FIGUR 25 illustrerer, hvordan systemet håndterer detektionen af forskellige typer af bakker, ved at måle recall og confidence for sorteringen. Her præsenteres også sammenhængen mellem præcision og recall, som giver os en forståelse af systemets nøjagtighed ved håndtering af sorte bakker fra forskellige producenter. Der er primært blevet gjort brug af computer vision modellen YOLOv7, med henblik på at systemet skal respondere så hurtigt som muligt uden at gå på kompromis med kvaliteten og kvantiteten i en grad, som er uhenigtsmæssig for sorteringen.



FIGUR 24. Precision-recall kurve for YOLOv7-modellen på sorte plastbakker.

I FIGUR 24 sammenlignes systemets præcision og recall for hver type bakke. Generelt ser vi en høj præcision for de fleste bakker, især for **Faerch M2270** og **Faerch type 2**, der begge ligger tæt på en præcision på 0.8 ved højere recall-værdier. Dette tyder på, at systemet formår at opretholde en god balance mellem at fange de korrekte bakker og undgå falske positive. For **Faerch Danish Crown** bakker ses en lavere præcision, hvilket indikerer, at der er plads til forbedringer i genkendelsen af denne type eller at bakken kommer i uregelmæssige former/udgaver.



FIGUR 25. Resultater for YOLOv7-modellen på sorte plastbakke.

FIGUR 25 præsenterer en forvekslingsmatrix (confusion matrix), der viser systemets præstation i at genkende forskellige typer sorte kødbakker. Matricen illustrerer, hvordan systemet har klassificeret bakkerne baseret på de forventede (sande) klasser versus de faktiske (forudsagte) klasser. De mørkere felter angiver en højere grad af korrekt klassifikation, mens de lysere felter indikerer hyppigere forvekslinger.

Det fremgår af matricen, at systemet præsterer bedst med **tray_black_Faerch M2270**, hvor det har en høj præcision i korrekt at klassificere denne bakke. **Tray_black_Faerch type 2** klarer sig også godt, men vi ser flere forvekslinger med andre bakker, især **tray_black_Faerch Danish Crown** og **tray_black_other**.

Desuden er der tydelige forvekslinger mellem bakker, der er delvist skjulte (**Occluded**) eller knuste (**Crushed**), hvilket indikerer, at systemet har sværere ved at håndtere bakker, der ikke er i perfekt stand. Dette antyder, at systemet i tilfælde er udfordret med hensyn til robusthed over for ufuldstændige eller beskadigede objekter.

3.6.1 Resultater for klassificering af sorte plastbakker på ARC

Resultaterne fra YOLOv7 viste at det ville blive svært at træne en model til at både detektere de sorte plastbakker, samtidig med at identificere hvilken specifik type bakkerne er. Som det kan ses på FIGUR 7, så er YOLO v7 god til at detektere hvor i billedet en bakke er, men har problemer med at identificere hvilken type bakke det er. Derfor blev det nødvendigt at splitte problemet op i to modeller. YOLOv7 vil forsat detektere bakkerne på båndet, mens en ResNet-18 model vil identificere bakkerne.

Ved at lade YOLOv7 lokalisere en bakke i et billede, kan den bakke "klippes" ud og det udskårne billede af bakken kan gives til ResNet-18 modellen for identifikation.

For at træne den bedst mulige ResNet-18 model, blev det vigtigt at holde de forskellige bakkeklasser rene, sådan at hver bakke er genkendelige. Det giver de bedste træningsmuligheder for at modellen kan lære de unikke karakteristika for hver type bakke. De klasser IHFood valgte i første omgang at arbejde med er de samme klasser som der blev testet på for at måle præstationen af YOLOv7, bakke-klassernes navne er dog forkortet til: **FaerchDanishCrown**, **FaerchType2** og **FarchM2270**.

Efter træning blev modellen evalueret på et test set bestående af ukendt data for modellen. Hvilket gav de følgende resultater:

TABEL 4. Forvekslingsmatrice for indledende ResNet-18 præstation på Færch bakke-klasser.

Resultat Forventet	Færch Type 2	Færch Danish Crown	Færch M2270	Occluded	Crushed	Other
Færch Type 2	95,51%	51,28%	0,0%	1,28%	1,92%	0,0%
Færch Danish Crown	2,56%	94,87%	0,0%	0,85%	0,85%	0,85%
Færch M2270	0,0%	0,0%	100%	0,005	0,0%	0,0%
Occluded	2,69%	3,76%	2,15%	86,02%	2,69%	2,69%
Crushed	0,0%	0,90%	2,70%	19,82%	65,77%	9,99%
Other	0,0%	4,44%	0,74%	9,63%	2,96%	82,22%

Sammenligner man resultaterne for identifikation af bakker med resultaterne fra testning af YOLO v7 i kan det let ses at ResNet-18 er en del bedre til at differentiere de forskellige bakke-klasser. Der er dog stadig noget overlap mellem de forskellige klasser. Det mest signifikante overlap er mellem **FærchType2** og **FærchDanishCrown**. Men dette overlap skyldes primært at begge klasser indeholder bakker, med bunden vendt opad, og med de unikke features dækket af en etikette. Eksempler på dette kan ses i FIGUR 26.



FIGUR 26. Eksempler på FaerchDanishCrown bakke med bunden opad til venstre, og en FaerchType2 med bunden opad til højre.

Da det nu er vist at man kan få langt bedre identifikation af bakke typer har IHFood valgt at tilføje to nye bakke klasser til modellen. Disse bakker måtte først annoteres efter samme annoterings standard som de eksisterende 3 bakke klasser, hvorefter modellen blev testet til følgende præstation, som set på TABEL 5.

TABEL 5. Forvekslingsmatrice for endelig ResNet-18 præstation på alle bakke-klasser.

Resultat Forventet	Faerch Type 2	Faerch Danish Crown	Faerch M2270	Hilton Foods1	Take Away	Occlu- ded	Crushed	Other
Faerch Type 2	98,06%	0,65%	0,00%	0,00%	0,00%	0,65%	0,00%	0,65%

Resultat Forventet	Faerch Type 2	Faerch Danish Crown	Faerch M2270	Hilton Foods1	Take Away	Occlu- ded	Crushed	Other
Faerch Danish Crown	0,005	95,76%	0,00%	0,00%	0,00%	1,69%	0,80%	1,69%
Faerch M2270	0,0%	0,0%	95,16%	0,00%	0,00%	0,00%	1,61%	3,23%
Hilton Foods1	0,0%	3,77%	0,00%	92,45%	0,00%	0,00%	0,00%	3,77%
Take Away	0,00%	0,00%	0,00%	0,00%	89,47%	0,885	0,00	9,65%
Occluded	4,97%	1,10%	0,55%	1,10%	0,55%	82,87%	2,72%	6,08%
Crushed	0,00%	4,10%	0,00%	2,46%	0,00%	16,39%	60,66%	16,39%
Other	0,0%	1,90%	0,00%	0,95%	3,81%	9,52%	1,90%	81,90%

Ved at inkludere to bakkeklasser mere taber modellen ikke noget af sin gode præstation på **FaerchType2**, **FaerchDanishCrown**, og **FaerchM2270**. Samtidig er præstationen **HiltonFoods1** 92.45% korrekt detekteret, og 89.47% korrekt detekteret **Takeaway** bakker. Samtidig er der et meget lille overlap mellem bakke typerne. Der er kun **HiltonFoods1** bakker som har et signifikant overlap med **FaerchDanishCrown** på 3.77%, endda uden at **FaerchDanishCrown** bakker har et overlap med **HiltonFoods1**. Dette skyldes at der er signifikant færre eksempler på **HiltonFoods1** i alle datasæt sammenlignet med **FaerchDanishCrown**.

3.6.1.1 Fejlklassificering

Selvom modellen har en høj præstation, laver den stadig nogle fejl. Særligt **Takeaway** bakker er svære at differentiere fra en anden type bakke, som IHFood har valgt at kalde "Bakke med k-formet pindefigur". Denne bakke type er en del af klassen **Other**, men pga. de store ligheder med **Takeaway** bakker er det en udfordring for modellen at se forskel på **Takeaway** og **Other** klassen, hvilket resulterer i at 9.65% af **Takeaway** bakkerne bliver identificeret som **Other**. Eksempler på **Takeaway** og på "Bakke med k-formet pindefigur" kan ses i FIGUR 27.



FIGUR 27. En **Takeaway** bakke til venstre, og en "Bakke med k-formet pindefigur" til højre.

Overlappet på 3.77% af **HiltonFoods1** i **FaerchDanishCrown** skyldes små bakker med bunden vendt opad, og at hoved featuresne derfor er dækket. Et eksempel hvor ens de to bakker kommer til at se ud kan ses i FIGUR 28. Det er dog også værd at vide, at modellen kun fejler

på denne type **HiltonFoods1** bakker, og at den kun fejler på 4 bakker i alt. Men fordi der kun er 53 test eksempler af **HiltonFoods1** kommer disse 4 fejl vurderinger til at slå meget ud.



FIGUR 28. En fejlklassificeret HiltonFoods1 bakke med bunden opad til venstre og en korrekt detekteret FaerchDanishCrown bakke med bunden opad til højre.

Overlappet mellem klasserne **Occluded**, **Crushed**, og **Other** med de specifikke bakkeklasser er mindre betydelige. Dette er fordi at overlappet mellem **Occluded**, **Crushed**, og **Other** og bakkerne er modellen som detekterer bakker i disse andre kategorier. F.eks. har den trænet ResNet-18 model fundet en **FaerchDanishCrown** bakke i **Occluded** (se FIGUR 29), men denne bakke er foldet, og ligger under en ketchup flaske. Model er altså i stand til at identificere bakkerne selv når de er delvist knuste eller overdækket.



FIGUR 29. Eksempel på en FaerchDanishCrown bakke fundet af modellen som er delvist overdækket af en ketchup flaske.

Alle fejlklassificeringerne model laver er på grænsetilfælde hvor to klasser minder meget om hinanden. Disse fejl kan forbedres med flere eksempler på bakker i grænseområderne, hvorved modellen lærer hvordan grænsetilfældene skal behandles.

3.6.2 Resultater for klassificering af sorte plastbakker, Damifo Vojens

Udover at træne og teste den trænede ResNet-18 model på data fra ARC besluttede IHFood også at undersøge hvor godt modellen ville præstere på data fra en helt anden affalds anlæg. Idet IHFood havde optaget data hos Damifo i Vojens, blev dette data valgt til denne test. Modellen har ikke trænet på billeder af bakker fra Damifo, kun testet. Resultaterne fra testen kan ses i TABEL 6.

Da dataet fra Damifo er en blanding af alle typer plast affald måtte de 14.820 billeder af plast bakker af forskellige typer manuelt annoteres, sådan at et verifikationssæt med kun **FaerchType2**, **FaerchDanishCrown**, **FaerchM2270**, **HiltonFoods1** og **Takeaway** kunne konstrueres. Verifikationssættet blev annoteret efter de samme regler som dataene fra ARC, og alle billeder af bakker som var genkendelige af mennesker, blev med taget i sættet.

Det resulterede i et sæt med fordelingen som ses i TABEL 6.

TABEL 6. Fordelingen af antallet af bakker som var genkendelige i dataet optaget hos Damifo.

Faerch Type 2	Faerch Danish Crown	Faerch M2270	Hilton foods 1	Takeaway
227	112	127	89	8

TABEL 7. Forvekslingsmatrice for den trænedes models præstation på Damifo data. Modellen er omtalt i Sektion 3.6.1., og er kun trænet på data fra ARC.

Resultat Forventet	Faerch Type 2	Faerch Danish Crown	Faerch M2270	Hilton Foods1	Take Away	Occluded	Crushed	Other
Faerch Type 2	96,92%	0,44	0,000%	0,00%	0,00%	0,00%	0,00%	2,64%
Faerch Danish Crown	1,79%	79,46%	0,0%	4,46%	0,00%	0,00%	0,00%	14,29%
Faerch M2270	0,00%	0,00%	89,76%	2,36%	0,00%	0,00%	0,00%	5,51%
Hilton Foods1	0,00%	1,12%	0,00%	89,76%	2,36%	0,00%	1,57%	0,79%
Takeaway	0,00%	0,00%	0,00%	0,00%	37,50%	0,00%	0,00%	62,50%

Selvom modellen ikke er har trænet på data fra Damifo formår den alligevel at finde 96.92% af **FaerchType2** bakkerne, 79.46% af **FaerchDanishCrown**, 89.76% af **FaerchM2270**, 93.63% af **HiltonFoods1** og 37.5% af **Takeaway** bakker.

3.6.2.1 Forskelle på sorte plastbakker hos ARC og Damifo Vojens

Grunden til den relativt lave præstation på **Takeaway** bakker hos Damifo skyldes primært at der kun er fundet 8 billeder af denne type bakker blandt alle billederne. Samtidig er **Takeaway** bakkerne hos Damifo også langt mere deformerede end ved ARC (se FIGUR 30). Bakkerne hos Damifo er generelt mere knuste, fordi plast affaldet bliver komprimeret ved opbevaring stederne, inden det bliver transporteret til Damifo, hvor der passerer igennem en kompaktor. Det gør alle bakker signifikant mere besværlige at genkende.

Resultaterne fra denne test viser altså at det er muligt at træne en model på relativt rent data, og bruge den samme model til at identificere de samme bakketyper i betydeligt svære situationer. Modellens præstation er der dog afhængig af at det er muligt at se mere end 1/3 af bakken, at bakken ikke er knust til ugenkendelighed, og at nogle karakteristika ikke er dækket af etiketter. Ligesom testen fortaget på bakker fra kun ARC i Sektion 3.6.1.

FIGUR 31 viser et eksempel på hvor anderledes bakkerne ser ud hos ARC og Damifo. I eksemplet er der udvalgt en almindelige **FaerchType2** fra ARC og en af de pæne **FaerchType2** bakker i verifikationssættet fra Damifo. Det ses tydeligt at det er meget svære at genkende selv en pæn bakke fra Damifo, sammenlignet med bakker fra ARC.

På bakke fra ARC ses tydeligt de små fordybninger samt de små hævede "diamanter" som udgør de unikke karakteristika for en **FaerchType2**. Disse karakteristika er langt svære at spotte på bakken fra Damifo. Man kan se at der del små fordybninger, men der er også andre typer bakker som har disse. Derfor skal modellen være i stand til at hive de relevante karakteristika ud af billedet, også selvom bakken er blevet krøllet og mast flad. Hvilket modellen lykkedes med.



FIGUR 30. Til venstre ses en typisk Takeaway bakke fra ARC, til højre ses en Takeaway bakke fra Damifo.



FIGUR 31. Eksempler på hvor anderledes lyset og standen af FaerchType2 bakker er. Denne forskel mellem ARC og Damifo bakker er meget typisk.


3.6.3 Resultater for klassificering af fødevarekartoner

Billederne blev inddelt i 50 % trænings data, 25 % validerings data og 25 % test data. Nedenstående ses resultaterne for den bedste ResNet18 model, der blev trænet på disse billeder.


TABEL 8. Forvekslingsmatrice over ResNet-18 modellens præstation på at adskille fødevarekartoner.

Resultater Forventet	Antal Billeder i testsættet	FoodCartonAcidic	FoodCartonNonAcidic
FoodCartonAcidic	83	83,13%	16,87%
FoodCartonNonAcidic	366	3,28%	96,72%

Resultaterne viser, at en model korrekt kan adskille **FoodCartonNonAcidic** (ikke-syreholdige fødevarekartoner) fra **FoodCartonAcidic** (syreholdige fødevarekartoner) med over 96 % præcision. Modellen kan derimod kun adskille **FoodCartonAcidic** fra **FoodCartonNonAcidic** med 83,13 % præcision. Nedenstående er nogle eksempler på fejlklassificerede billeder.



FIGUR 32. Eksempler på fejlklassificerede **FoodCartonAcidic** billeder.



FIGUR 33. Eksempler på fejlklassificerede **FoodCartonNonAcidic** billeder.

Fejlklassificeringerne skyldes delvist, at datasættet er ujævnt fordelt, dvs. at der er flere eksempler af **FoodCartonNonAcidic** fødevarekartoner end **FoodCartonAcidic**. Dette kan indføre en såkaldt bias til modellens forudsigelser ift. at forudsige **FoodCartonNonAcidic** fødevarekartoner. På trods af dette, er præcisionen på de syreholdige billeder tilstrækkelig god til at det er tydeligt at modellen er i stand til at adskille kartonerne og ikke altid forudser ikke-syreholdige.

Derudover, er de to klasser meget alsidige; hver klasse indeholder mange typer fødevarekartoner fra forskellige producenter, hvilket gør at hver enkelt fødevarekarton i datasættet ikke nødvendigvis er repræsenteret tilstrækkeligt med billeder. Det er derfor f.eks. ikke gængse danske Rynkeby juicekartoner eller danske mælkekartoner der er underrepræsenterede, men nærmere tyske juice og mælkekartoner.

Afslutningsvist, er problemet med at klassificere fødevarekartoner i en affaldsstrøm besværligt, eftersom fødevarekartonerne kan være delvist overskyggede af andre objekter og kan være beskidte eller knuste mm. Derfor er variationen i fødevarekartonerne i en affaldsstrøm betydeligt større end nye fødevarekartoner og der er derfor et større behov for at optage mere data, så modellen har mulighed for at indlære denne variation.

3.7 Udvikling af algoritme til undersøgelse af kemisk sammensætning for plastprodukter

Der er en række algoritmer, der kan anvendes til undersøgelse af kemisk sammensætning af plastprodukter, afhængigt af den specifikke opgave. Gængse teknikker er:

- NIR-spektroskopi er baseret på vekselvirkningen af NIR-lys med molekulære vibrationer og rotationer, hvilket gør det muligt at bestemme den molekulære struktur og sammensætning.
- Raman-spektroskopi: Dette er en non-destruktiv teknik, der bruges til at identificere polymerkomponenter og deres sammensætning.
- Fourier Transform Infrarød (FTIR) spektroskopi: Dette er en anden non-destruktiv metode, der bruges til at identificere polymerkomponenter ved at måle deres vibrationelle energier.
- Kernemagnetisk resonans (NMR) spektroskopi: Dette er en destruktiv metode, der bruges til at identificere polymerkomponenter ved at måle deres magnetiske egenskaber.
- Massespektrometri: Dette er en destruktiv metode, der bruges til at bestemme den præcise sammensætning af polymerkomponenter ved at måle deres masse.


IHFood har valgt at basere vores undersøgelse på NIR spektroskopi. Kamera og lys (se Sektion 4.1.2 for detaljer) er installeret i IHFood's eget laboratorium (se FIGUR 34) og matcher installationen på ARC, samt opsætning af softwaren og kommunikation.




FIGUR 34. Opsætning af spektral-kamera og sorteringsrobot i IHFood Lab.

3.7.1 Undersøgelse af plastiksortering i NIR-spektrum

Der er dermed foretaget en undersøgelse af forskellige plastiktysers kemiske sammensætning, mhp. plastiksortering med et SWIR-kamera der optager i et NIR-spektrum (946nm-1742nm). Resultaterne kan ses på FIGUR 35. Derudover findes der en emneliste med alle emner som er brugt i undersøgelsen af SWIR kameraets brug til plastiksortering i Bilag 1.2.



FIGUR 35. Gennemsnits-reflektansspektrum af plastiktyserne PET, ABS, LDPE, HDPE, PP, PVC.



FIGUR 36. Gennemsnitsspektrum af plastiktyserne hvor spektrene er blevet justeret med et offset så de har samme startreference. Der er markeret de spektralområde hvor gennemsnitsspektrene har størst difference.

Det kan ses af FIGUR 35, som viser en afbildning af gennemsnitsspektre af 6 forskellige plastiktysere fra de forskellige emner (J.F. emneliste), at der kan findes en forskel i reflektansspektrum mellem forskellige typer plastik. FIGUR 36 viser gennemsnitsspektre fra de førnævnte plastiktysere hvor de er givet et offset ift. en reference, og herefter er gennemsnitsspektrene

subtraheret fra hinanden. De røde mærkninger som kan ses på figuren, er de bølgelængder hvor forskellen mellem spektrene er størst, og er en indikation på hvor reflektansspektraene adskiller sig fra hinanden.


Fra begge figurer kan det ses at der kan findes en forskel i både intensitet men også i selve intensitetsprofilen for de forskellige plastiktyper. Her skal det dog nævnes at farven fra de undersøgte emner kan have indflydelse på selve intensiteten, og selvom der er taget et gennemsnits af alle emner med samme plastiktyper, vil dette formentlig stadig være en fejlkilde i sammenligningen mellem de forskellige plastiktypers intensitetsprofiler. Det kan derudover også ses at de spektralbånd hvor der er den største gennemsnitlige forskel mellem kurverne er i den høje ende af NIR-spektret, men at der også er områder igennem spektret med større difference. Dette tyder på at de vigtigste spektralområder ift. At differentiere af plastiktyper i et NIR-spektrum er i den høje ende, men med enkelte vigtige markører spredt ud gennem spektret.



FIGUR 37. Greyscale visualisering af emne med 3 typer plastik og Markering af pixels med spektrum tilsvarende plastiktypen A) PP B) HDPE C) LDPE.

Forskellen mellem forskellige typer plastik er yderligere verificeret, ved at afprøve muligheden for genkendelse af plastiktyper fra samme emne, som kan ses på FIGUR 37. På figuren er områderne af emnet color-gradet efter i hvor stor grad at området deler samme gennemsnits-spektrum. Som det kan ses, stemmer de farvede områder relativt overens med emnets 3 forskellige plastik typer, som kan ses i emnelisten.


Der kan også bemærkes uregelmæssigheder, hvilket kan skyldes at den ene plastiktype var glans, hvilket betyder at der er tilsat kemiske forbindelser som i visse tilfælde kan give et styrket reflektansspektrum tilbage. Dette kan blandt andet ses på de "hvide" pletter på NIR-billederne af emnerne.



FIGUR 38. Sammenligning af spektra af transparent HDPE-flaske på mørk og lys baggrund.

3.7.2 Undersøgelse af forskelligt farvede plastemner og baggrunde

Der er også videre undersøgt hvorvidt baggrunden hvor disse målinger foretages kan influere reflektansspektrummet og have indflydelse på hvorvidt samme plastiktype kan genkendes. Dette kommer af en problemstilling hvor emner af transparent plastik havde en lav reflektanskurve for NIR-spektret på en mørk baggrund. På en lys baggrund viste samme emner en større forskel mellem de forskellige spektralbånd og en større samlet intensitet, hvilket muliggør en differentiation mellem forskellige plastiktyper, omend der for transparente plastiktyper gælder at forholdene mellem individuelle spektralbånd, og dermed særprægede spektrale kendetegn for hver plastiktype formindskes. Årsagen til dette skal formentlig findes ved at størstedelen af det nær-infrarøde lys ikke bliver reflekteret direkte fra den transparente plastik overflade, men i stedet når ned til den mørke baggrund hvor det her bliver absorberet. Med den lyse baggrund bliver lyset reflekteret tilbage gennem emnet og reflektansspektrummet fra emnet bliver derfor synligt, omend svagere end ved et emne af samme plasttype som ikke er transparent.



FIGUR 39. De 5 mest betydende spektralbånd ift. Klassificering af plastiktyperne HDPE, PP, PVC, PS, ABS og PET.


Der er, for at undersøge hvilke spektralbånd og kendetegn der er vigtige for denne differentiation mellem de forskellige spektre, blev foretaget PCA, både med henblik på en undersøgelse af muligheden for at benytte machine learning til genkendelse af plastiktyper, men også for at undersøge hvilke spektralbånd som kan bruges for at finde den største forskel.

For at lave denne undersøgelse blev spektraldata for de 6 plastiktyper PP, HDPE, PET, ABS, PS og PVC benyttet.

Efter træningen af modellen blev data fra et, for modellen ukendt, emne produceret af plastiktypen HDPE testet, og modellen fandt at 97.66% af dataene skulle stamme fra HDPE plast, mens 2.34% af daten skulle stamme fra PP-plastik. På samme måde blev de forskellige plastiktyper testet på modellen, hvor HDPE med 97.66% havde den højeste genkendelse mens PP med 87.32% havde den laveste af plastiktyperne. Dette vurderes umiddelbart til at være gode resultater taget mængden af tilgængelige data i betragtning.


Derudover fandt modellen, som det kan ses af FIGUR 39, at de vigtigste bølglængder ift. bestemmelse af plastik typer skal findes i den øvre del af NIR-spektret. Dette kan sammenholdes med den førnævnte FIGUR 38, som indikerer det samme. Dette er også noget som er yderligere underbygget i artiklen *plastic classification via in-line hyperspectral camera analysis and unsupervised machine learning*.⁷

Det er dog vigtigt at understrege at der i forbindelse med PCA som sagt har været begrænset data tilgængelig, og at der i undersøgelsen derfor kun kan vises indikationer og denne undersøgelse kan derfor ikke betragtes om en udvikling eller benyttelse af en model til klassificering af plastiktyper.




FIGUR 40. Gennemsnitsspektra mellem to emner af samme plastiktype (PP) men med forskellige farver grå og rød.

⁷ Henriksen et al., *Plastic classification via in-line hyperspectral camera analysis and unsupervised machine learning*, *Vibrational Spectroscopy* (2022)



FIGUR 41. Sammenligning af gennemsnitsspektra for samme emnetype og plastiktype ABS, med farveforskel i det synlige spektrum.



FIGUR 42. Reflektansspektrum fra sorte PET-bakker på lys og mørk baggrund.

Et vigtigt nedslagspunkt er de forskelligheder som forskellige farver af samme type kan give ved en måling af NIR-spektret. Dette kan b.l.a. ses på FIGUR 41, hvor der kan observeres en forskel i spektrum-intensitet mellem to emner af forskellige farver med samme plastiksammensætning. Det overordnede spektrum ligner at have samme forhold mellem de forskellige spektralbånd, men hvor det er klart at emnet med den grå farve har en vagere fremstilling. Dette kan som nævnt også observeres på figur hvor de farver der i synligt lys observeres mørkere, også har et homogent reflektansspektrum, dog med forskellige intensiteter. Dette understreges yderligere ved at kigge på FIGUR 41, hvor det kan ses at sorte PET-bakker har en meget lav reflektans uden særlige markører der ville kunne gøre det muligt at adskille dem fra andre typer plast.

Dette skyldes, at for mørkere plastiktper tilsættes der carbon som det kemiske farvestof, hvilket i denne sammenhæng, har den ulempe at det absorberer klart størstedelen af lyset i NIR-området, hvilket dermed gør det nær umuligt at skelne mellem to forskellige plastiktper, hvis begge plastiktper er tilsat dette kemiske farvestof.


Fra FIGUR 41 er det også muligt at observere en stor forskel mellem de "synligt" mørkere farver af ABS og de lysere farver. Årsagen til dette skal med stor sandsynlighed også findes i måden plastik farves mørkere på, altså tilsætningen af carbon og andre farvestoffer som har

en større grad af absorbering ift. bølgelængderne i NIR-spektret. For de lysere farver gælder dog, at deres spektre er relativt ens, med undtagelser.

Dette bunder i at ABS er et blandingsprodukt, og den specifikke kemiske sammensætning for de emner som er blevet brugt i denne undersøgelse, er ikke kendt. En forskellig kemisk sammensætning, vil resultere i forskellige reflektansspektra.


For at kunne klassificere hvilken type plast som et sort emne er lavet af, skal man derfor kigge udover det spektralområde som denne undersøgelse har gjort brug af.

Det er også undersøgt hvorvidt en længere exposure time for kameraet kan muliggøre at de individuelle forhold mellem bølgelængderne for de "mørkere" plastikfarver kan observeres. Dette kan ses fra graferne på FIGUR 43. Ud fra dette kan der umiddelbart ikke observeres meningsfulde markør-ændringer for det undersøgte spektra.



FIGUR 43. Sammenligning af reflektansspektra for grå legoklods i ABS (venstre) og sort legoklods i ABS (højre) med forskellige eksponeringstider.

3.7.3 Undersøgelse af fødevarekartoner i NIR-spektrum



FIGUR 44. Sammenligning af reflektansspektrum af karton fra mælk og tomatjuice.

Der er yderligere blevet undersøgt hvorvidt det var muligt at måle en forskel i NIR-spektret mellem karton som har indeholdt mælk og tomatjuice. Denne undersøgelse blev lavet mhp. om kartoner kan sorteres med SWIR kamera, da kartoner der har indeholdt syrlige væsker,

ikke kan sorteres med karton der har indehold neutralt eller basale væsker. Tomatjuice er blevet valgt da den har en sammenlignelig pH-værdi som f.eks. appelsinjuice og en række andre typer juice.

Ud fra grafen er det dog muligt at se, at der er lille forskel på reflektansspektret, og at der ud fra dette ikke er nogen indikation på at der i NIR-spektret kan observeres forskel på karton.

Intensitetsforskellen der dog kan observeres, kan formentlig forklares ved at de to kartoner som er undersøgt, har forskellige farver, og dermed forskellige niveauer af absorption, som tidligere undersøgt.

3.7.4 Del-konklusion af undersøgelser i NIR-spektrum

Der kan ud fra de foregående resultater udledes at NIR-kameraet kan bruges til at differentiere og klassificere forskellige typer af plastik baseret på deres kemiske sammensætning, vel og mærke begrænset til at sorte eller relativt mørke farver ikke kan differentieres da reflektansen i NIR-spektret er relativt homogent og ikke differentierbart, og at en længere eksponeringstid eller mere lys ikke løser dette problem.

Der kan også udledes at det gælder for transparente plastiktyper at baggrunden har betydning for det målte reflektansspektrum, og at der gives bedre resultater ved en lys baggrund for transparente emner. Det kan ses ud fra undersøgelsen at for de undersøgte plastiktyper er de vigtigste spektralbånd placeret i slutningen af NIR-spektret, dog med undtagelser og enkelte områder gennemgående i spektrummet. Der til slut konkluderes at der ikke kan observeres en forskel i hvilken type væske karton har indehold udelukkende ved brug af en hyperspektral undersøgelse i NIR-spektret.

4. Arbejdspakke 3: Udvikling af closed-loop sorteringskoncept


4.1 Opstilling i laboratorie

Jfkl I laboratoriet hos IHFood er der opstillet en sorteringsrobot, samt robotcontroller. Udstyret er identisk med det der er installeret på ARC. Denne installation er blevet brugt til udvikling af robotkommunikationen og generel test af applikationen. Opsætningen kan ses på FIGUR 51.

4.1.1 Udvikling af mekanisk design

Der er foretaget en simple analyse af produktionsbehov og af de opgaver, som robotten skal udføre, samt de krav, der er til produktionshastighed og præcision. Det fysiske arbejdsområde er defineret, som robotten vil bevæge sig i, og eventuelle begrænsninger er afdækket. Der er lavet en sikkerhedszone omkring robotten, som beskytter mennesker og andre objekter mod potentiel kan kollision med robotten.


ABB FlexPICKer, er blevet programmeret til at plukke en bestemt type produkt fra båndet og placere den i en beholder. Desuden er start, stop, pause positioner defineret.



FIGUR 45. Robottens arbejdsradius, sikkerhedszonen for robotten og den taktiske arbejdsradius.

FIGUR 45 giver et overblik over robottens arbejdsområder. Den sorte cirkel er robottens teoretiske arbejds radius, Den røde firkant er sikkerheds zonen som IHfood har lavet for at robotten ikke støder på kanten på f.eks. båndet. Den blå faktiske arbejdszone hvor der samles plast emner op.

I FIGUR 46 er emners placering på båndet og hvordan vores algoritmen vælger emner inden for **opsamlingszonen** og drop zonen illustreret.



FIGUR 46. Arbejds-flow for opsamling af plastemner.

Der er **implementeret** en brugerflade, der giver brugeren mulighed for at kommunikere med robotten og robotten er blevet testet for eventuelle fejl eller mangler.

4.1.2 Procesoptimering

For at procesoptimere tidsforbruget har vi set på hvad der er mest tidskritisk og i denne sammenhæng er det de kritiske software komponenter så som billedbehandling, detektion og kommunikation med robotten.

Der er brugt GPU-acceleration for billedbehandlingen for at reducere den tid, der kræves pr. billede og region-baseret behandling, hvor kun vigtige billedområder bliver behandlet detaljeret, og mindre vigtige områder bliver ignoreret.

Endvidere er der brugt optimerede modeller som YOLOv7 og ResNet-18 og eksperimenter med forskellig modelstørrelse og dybde for balancering mellem hastighed og nøjagtighed.

Der er arbejdet på at reducere ventetiden mellem detektion og kommandooverførsel til robotten og at, visionsystemet og robotten arbejder i samme koordinatsystem og at timing-controlleeren er kalibreret med høj nøjagtighed for at sikre, at signalerne er korrekt synkroniserede for at undgå kommunikationsflaskehalse.

4.1.2.1 Procesoptimering Robot


De følgende billeder illustrerer, hvordan Flexpicker opererer under en opsamlings- og sorteringsproces.

De følgende billeder viser Flexpickers funktion i en opsamlings- og sorteringsproces, hvor den gennem præcise bevægelser optimerer opsamlingen af sorte fødevarebakker. Hvert billede illustrerer specifikke aspekter af robotens måde at håndtere objekter præcist.



FIGUR 47. Illustration af Flexpicker opererer under en opsamlings- og sorteringsproces.

På FIGUR 47 ses Flexpicker i en lodret position under opsamling af fødevarebakken. Armen bliver justeret, så sugekoppen bliver placeret midt på bakken. FIGUR 47 viser, hvordan robotten løfter fødevarerbakken op og bevæger sig mod drop stationen.



FIGUR 48. Illustration af Flexpicker opererer under en opsamlings- og sorteringsproces.

For at øge opsamlingsraten har vi forsøgt med en proces der kan sammenlignes med en rovfugl, der dykker mod sit bytte med fart, følger det kort for derefter at stige op.

FIGUR 48 viser, hvordan Flexpicker i en kontinuerlig nedadgående vinkel møder fødevarebakken i en glidende bevægelse, følger med i bakkens bevægelses retning for en meget kort stud for derefter at stige op. Ved at lade Flexpickeren følge fødevarebakken opnås mere tid for sugekoppen til at skabe mere undertryk og dermed bedre at kunne holde fast i fødevarebakken. Dette øget pick-up raten med ca 20% point.

Ved at udskifte den traditionelle vakuumejektor, PIAB P3010 Mini Si08-3 (FIGUR 49), med den kraftigere PIAB P5010 med 2 moduler Si32-3 (FIGUR 50), blev det muligt at skabe et vakuumniveau, der var 90% mere effektivt.



FIGUR 49. PIAB P3010 Mini Si08-3 vakuumejektor.



FIGUR 50. PIAB P5010 vakuumejektor med 2 moduler Si32-3.


Den oprindelige vakuumejektor fjernede 1 liter luft på 0,25 sekunder ved 20 kPa, mens den nye løsning, PIAB P5010, klarer samme opgave på blot 0,025 sekunder, hvilket gør den omtrent 10 gange så kraftig.

PIAB P5010 er designet til højtydende vakuumsystemer og kan levere et vakuumniveau på op til 98 kPa med høj effektivitet og samtidigt lavt energiforbrug. Dette øgede vakuum har gjort det muligt at opsamle en betydeligt større mængde produkter mere korrekt og effektivt. Det antages, at ved korrekt håndtering og processering af produkterne inden opsamlingsprocessen, vil systemet opnå både øget sorteringsevne og hurtigere håndtering.

Derudover medfører den forbedrede vakuumejektor ikke kun øget hastighed og effektivitet i opsamlingsprocessen, men kan også resultere i potentielle besparelser på energiforbruget. PIAB P5010 er designet til at fjerne luft hurtigere ved et lavere energiforbrug, hvilket kan reducere driftsomkostningerne over tid. Den forbedrede præcision og håndtering betyder også færre fejl og mindre spild under sorteringen, hvilket bidrager til en højere produktkvalitet. Samlet set fører denne opgradering til øget gennemløb i produktionen, hvor både hastighed og nøjagtighed optimeres.

4.1.2.2 Systemintegration og afprøvning i laboratorie

IHFood har opbygget identiske installationer så vores lokal en magen til den på på ARC: Formålet er afprøve og test hardware og software lokalt før vi sætte det ud i et live produktions anlæg. Opsætningen kan ses på FIGUR 51.



FIGUR 51. Transportbånd med sorte fødevarebakker og robot i IHFood lab.

Billederne i FIGUR 52 viser forsøg med lysopsætningen. Her arbejdes det på at kalibrerer det hvide lyse ved at se på rød, grøn og blå for at sikker at man får det samme hvide lys ud hver gang.



FIGUR 52. Testbilleder optaget af plastobjekter i IHFood lab med forskellig lysopsætning.

5. Arbejdspakke 4: Afprøvning på testanlæg

5.1 Installation på testanlæg

Før installationen er der udarbejdet en plan for, hvordan robotten skal installeres og integreres i lab og produktionsområdet. Dette inkluderer også at bestemme, hvor robotten skal placeres, og hvordan den skal tilsluttes til andre enheder og systemer

Robotterne er monteret i LAB og på ARC, herunder armen, og kontrolkabinettet.

Robotteren er tilslutte strøm og netværk og der er foretaget konfiguration af elektriske komponenter samt kamera. Der er foretaget konfiguration af robotens software, herunder installation af programmet og opsætning af robotens bevægelsesmønster. FIGUR 53 viser robot opsætningen på ARC.



FIGUR 53. Sorteringsrobotten på Amager Ressource Center.

5.2 Sugekop test på ARC

Som led i udviklingen af vores automatiserede sorteringssystem til sorte kødbakker gennemførte vi en test på Amager Ressource Center (ARC) med fire forskellige typer sugekopper, se FIGUR 54. Testens formål var at evaluere sugekoppens effektivitet i håndteringen af sorte kødbakker, der udgør en særlig udfordring på grund af deres farve og materiale.

5.2.1 Test med 4 forskellige sugekopper på 100 styk sorte kødbakker

Hver sugekop blev afprøvet på 100 sorte kødbakker, og resultaterne viste en klar forskel i ydeevnen. "Stor sort sugekop" opnåede den højeste succesrate med 60%, mens "orange sugekop" havde den laveste på 28%. Denne test gav os værdifuld indsigt i, hvordan forskellige sugekopdesign påvirker evnen til at gribe glatte og mørke overflader, hvilket er afgørende for at optimere sorteringssystemets præstation.



FIGUR 54. Oversigt over de fire testede sugekopper på sorteringsrobotten ved ARC.

Testene blev gennemført ved at montere hver sugekop på vores automatiserede system, som anvender maskinlæringsalgoritmer til at identificere og sortere kødbakkerne. Hver sugekop blev testet under ensartede, kontrollerede forhold for at sikre retfærdig sammenligning. Vi målte hver sugekop på dens evne til at løfte og flytte sorte kødbakker med præcist og sikkert greb.

Resultaterne giver os vigtige indsigter i, hvilke sugekopper og teknologiske justeringer der kan øge systemets effektivitet, især i håndteringen af udfordrende materialer som sort plast. Denne viden vil være afgørende for de næste trin i udviklingen af vores sorteringssystem.

TABEL 9. Resultater for test af sugekopper.

Test 1-100	Sorteringsrate Lille sort sug	Sorteringsrate Blå sug	Sorteringsrate Orange sug	Sorteringsrate Stort sort sug
1	-	-	-	+
	+	-	-	+
100	57%	35%	28%	60%

5.3 Test og optimering på testanlæg

Baseret på resultaterne af sugekop-testen på ARC er det tydeligt, at den store sorte sugekop er den mest effektive til håndtering af sorte kødbakker. Med en succesrate på 60% skiller den sig markant ud i forhold til de øvrige sugekopper, med undtagelse af den mindre sorte sugekop, der opnåede en succesrate på 57%.

Den store sorte sugekop er udstyret med en bred base og en skumpude langs kanten, som sikrer en tæt forsegling mod kødbakkerne. Dette design gør det muligt for sugekoppen at tilpasse sig overfladens konturer, hvilket resulterer i et stabilt og pålideligt greb. Skumpuden forhindrer desuden luft i at trænge ind, hvilket yderligere forstærker vakuumgrebet og mindsker risikoen for fejl.

Evnen til at opretholde et stabilt greb reducerer antallet af fejl og øger sorteringseffektiviteten. Derudover kan det sorte design bidrage til mindre kontrast mod de sorte kødbakker, hvilket reducerer lysrefleksioner og forbedrer grebets præcision. Dette gør den store sorte sugekop til et oplagt valg til fremtidig implementering i det automatiserede sorteringssystem. Samtidig viser den høje succesrate for den mindre sorte sugekop, at designet generelt er yderst effektivt.

For at optimere ABB FlexPicker-robots cyklustid, har vi set på såvel softwaren som hardwaren, for at forbedre robotens ydeevne og dermed reducere cyklustiden.

For at optimering af robotens bevægelsesbane har vi defineret robotens start position så tæt på transportbåndet og emnerne som muligt. For at undgå kollision kunne vi ikke "parker" roboten over båndet da vi ikke kender højden på de emner der passer på båndet.

Vi har implementeret glidende bevægelsesovergange (soft transition) mellem punkterne, så roboten ikke stopper helt mellem hver position, men i stedet kan bevæge sig kontinuerligt. Ved brug af vores software vision platform som er et hurtigt eksekverende software system der foretager en hurtig billedbehandling har vi reduceret den tid, det tager at identificere og positionere emner på transportbåndet i forhold til robotens position. I samspil men en præcis kalibrering af kamerasystemet er der skåret væsentlig tid af hver cyklus. Det betyder bl.a. at roboten ikke venter på input fra visionsystemet,

Mht til sugekoppen har vi brugt en højt ydende vakuumejektor, som fx PIAB P5010, der sikrer hurtigere luftfjernelse og dermed hurtigere greb. Endvidere har vi for at optimere reduceret grebstiden ved at blæse førevarebakken af lige inden den er inden over afleverings området.

Ved en hitrate på 60% kan 54 emner opsamles i minutter og en (antaget) gennemsnitsvægt pr. emne på 20 gram, giver dette et teoretisk output på sorteringsanlæg på:

$$54 \text{ emner} \cdot 60 \text{ min} \cdot 8 \text{ timer} \cdot 250 \text{ dage} \cdot 20 \text{ g} = 129 \text{ ton Plast om året pr. robot.}$$

Ved en CO₂e-belasting på 2 g pr. gram plastisk, svarer dette til 259 ton CO₂e om året pr. robot.

6. Arbejdspakke 5: Formidling

6.1 Formidling af resultater og fremtidig udnyttelse

Vi har besøgt og talt med en række nøgleinteressenter og samarbejdspartnere inden for affaldshåndtering, genanvendelse og bæredygtighed. Disse besøg gav os en unik indsigt i de forskellige udfordringer og løsninger, der præger branchen og miljøområdet i forbindelse med et "closed Loop".

Fælles for dem alle var at de mener at vores approach er en god ide og at alle teknologier skal i spil for at lave en mere effektiv affaldshåndtering og højere genanvendelsesgrader.

Vi har deltaget i diverse workshop, såsom MADE Manufacturing Academy of Denmark, DAGOFA seminar, Loop, IFAD samt besøgt virksomheder, diverse forbrændingsanlæg, affaldsproducenter osv.

TABEL 10. Oversigt over key stakeholders vi har været i dialog med.

Pellenc ST	RTT Steinert	SWEREC	HCS	Marius Pedersen
RE Source	Solum	AMP Sortation	H.J.Hansen	
Affaldvarme Aarhus	Kars Noveren	Vest Forbrændingen	ARC	IVAR
BOFA	Damifo	Nomi4s	ReneNord	Reno Fyn
Ragn-Sell	WAMATech	Dansk Affaldsminimering	Novo Nordisk	Mldk
Dagofa	Dansk retur System	Dansk Natur Frednings Forening	Aage vestergaard Lars	Coop
Færch	Plus Park	Københavns Kommune		

Vi har talt med Stadler Anlagenbau A/G om muligheden for at sætte vores vision system op på deres test anlæg i Slovakiet men det er pt. reserveret af kunder til flere forsøg.

Vi har talt med Damifo om et vision system til deres anlæg til detektion af urtepotter og tomatbakker i tillæg til de sorte førewarebakker. De vil gerne havde at vi skal nå et krav om 95% renhed for 50% af emner

Under deltagelsen af dette års Loop konference (2024), Blev vores teknologi fremhævet i et oplæg at Københavns Kommune.

6.1.1 IFAD München

IHFood besøgte verdens største messe for miljøteknologier, IFAT Messen, i 2022. På dette tidspunkt var der 2.984 udstillere og omkring 119.000 besøgende. Der var specifikt fokus på cirkulære løsninger inden for blandt andet plast og byggematerialer. Vi talte med syv virksomheder, der arbejdede med kunstig intelligens (AI).

I 2022 var der kun omkring fem virksomheder, der arbejdede så specialiseret med AI og teknologi rettet mod industrien i samme kontekst som IHFood. I 2024 var dette antal nu 25+ virksomheder, der opererede inden for samme felt.

De fleste konkurrenterne arbejder med sortering af PET flasker. Vores system går et spadestik dybere og se på kategorier. Vi identificerer ikke bare at der er tale om en flaske, men om der er tale om en drikke flaske eller en fødevarebakke.

IHFood var bl.a. i dialog møder med følgende virksomheder på messen.

TABEL 11. Oversigt over virksomheder vi har været i dialog med på IFAD.

Stadler Anlagen- bau	MAX AI	Tomra	Gretparrot	RTT Steinert
BANo Recycling SRL	Sutco Recycling Tevhnik GmbH	Next Genertion Re- cyclingmaschinen GmbH	Weima Maschinenbau GmbH	ZenRobotics
Recco Non Ferro Metal B.V.	PreZoro Stiftung & Co.KG	Aurubis AG		

Foruden ovenstående virksomheder, fremgår der en totalliste over virksomheder, som IHFood var i kontakt med på IFAT 2024 i Bilag 1.3.

7. Konklusion

7.1 Konklusion

Projektet om genanvendelse af sorte fødevarebakker, som også er et generisk projekt til højere genanvendelse af plastic i almindelighed, er gennemført i perioden 2022-2024.

Projektet viser at ved brug af avancerede AI- og maskinlærings-algoritmer, herunder anvendelse af computer vision baseret primært på neurale netværk og avancerede annoteringsværktøjer, kan man udvikle et system, der kan detektere, kategorisere og sortere plasttyper, selv komplekse materialer såsom sorte fødevarebakker som tidligere har udgjort en væsentlig udfordring. En udvikling som vil gøre det mere rentabelt og dermed mere attraktivt at indsamle plastic.

En central del af projektet har været udviklingen af et Machine Vision-system med specialiseret kameraudstyr og lys, en IHFood Base Software til håndtering af billeder og billedbehandlingen af disse, fleksibel "machine learning model logistic" til håndtering af objekt-detektion med div. avancerede modeller og/eller kombineret med mere klassisk maskinlæring samt kontrol af robot(ter). I dette tilfælde en flexpicker robot til automatiseret sortering af plastic objekter på et kørende transportbånd – f.eks. plastic i form af sorte fødevarebakker.

Det udviklede "machine vision system" er generisk, det kan skaleres til flere kameraer og robotter, til flere parallelt kørende modeller til f.eks. objekt-detektion og dermed til håndtering af forskellige mængder affald.

Parallelt er NIR-spektroskopi testet som en alternativ metode til at identificere forskellige plasttyper ud fra deres kemiske sammensætning, og resultaterne viser, at man ikke kan identificere eller differentiere polymer af sort emner. Endvidere giver emner med flere plasttyper og emner i mørke nuancer udfordringer i forhold til at lave en "ren" sortering, "a clean stream".

For at komme i mål med en høj detektion af div. bakker i forskellig forfatning er der to faktorer, som spiller en vigtig rolle:

Et stort repræsentativt datamateriale fra affaldsstrømmen samt et vel-annoteret datasæt.

Projektet har i den grad understreget vigtigheden af et velannoteret datasæt og visuelle analysemetoder til at optimere AI-modellerne. Ved brug af værktøjer som CVAT og FiftyOne, og ikke mindst IHFoods egen view annoter har teamet kunnet forfine systemets præcision gennem omfattende billedannotering og embedded visualisering – værktøjer som bidrager til en robust sorteringsteknologi.

Ud over at levere en løsning med konkrete CO2e-besparelser og øget genanvendelsesrate har projektet således også etableret et stærkt brugbart skalerbart fundament for fremtidige samarbejder. IHFood er lykkedes med at udvikle et sorteringssystem, som fungerer

Projektet har demonstreret, at innovative AI-drevne visionsystemer baseret på korrekt annoteret datamateriale kan bidrage væsentligt til en højere genanvendelse af plastbakker og fødevarekartoner. Når det er muligt at skelne de sorte kødbakker fra hinanden – en svær opgave selv for mennesker og i volumen en umulig opgave for mennesker, så er det rimeligt at antage at systemet kan skelne andre plastemner.

Projektet kan bidrage til videreudvikling af mere effektive og bæredygtige affaldshåndteringssystemer og øge potentialet for closed-loop genanvendelse, hvilket er afgørende for at nå EU's mål om 65% genanvendelse i 2035.

Som et kuriosum kan det nævnes, at "machine vision systemet" vil kunne trænes til at kunne detektere alle mulige andre plastikprodukter og dermed tælle enheder på div. affaldsstationer – det kunne tænkes at være interessant i forbindelse med producentansvar for emballage og engangsplastprodukter som træder i kraft 2025.

8. Perspektivering

Forretningspotentialer i dette affalds- og sorteringssystem er betydeligt og manifesterer sig på flere måder:

1. Effektiv Affaldssortering og Reducerede Omkostninger

Ved at bruge et visionssystem til at sortere affald og identificere produkter efter producent, kan affaldscentre effektivisere sorteringsprocessen og reducere manuelle arbejdsomkostninger. Det automatiserede system kan også minimere fejl i sorteringen, hvilket sparer ressourcer og optimerer affaldsstrømmene.

2. Øget Genbrug og Salg af Genanvendelige Materialer

Systemet gør det lettere at identificere materialer, der kan genbruges og videresælges, hvilket øger mængden af genanvendelige produkter. Dette åbner muligheder for salg af materialer til genanvendelsesvirksomheder, hvilket kan blive en direkte indtægtskilde.

3. Producentansvar og Data til Bæredygtighedsrapportering

Klassificering af affald efter producent kan hjælpe virksomheder med at opfylde lovkrav om producentansvar og bæredygtighedsrapportering. Ved at tilbyde denne service til producenter, kan affaldscentre eller teknologileverandører skabe en indtægtsstrøm gennem abonnementer eller gebyrer for monitorering og rapportering af affaldsdata.

4. Tilbydelse af Mobil Sorteringsservice

Den mobile enhed gør det muligt at tilbyde sorteringsservice direkte ved lokale affaldscentre eller ved større bygge- og anlægsprojekter, hvor affaldsmængden er stor. Dette fleksible setup kan skabe nye markeder og potentielle kunder, som har behov for lokal og midlertidig affaldssortering.

5. Skabelse af Grønnere Image og CSR-værdi

Virksomheder, der anvender teknologien til at monitorere og forbedre affaldshåndteringen, kan positionere sig som bæredygtige og ansvarlige aktører. Dette kan tiltrække kunder og investorer, der vægter bæredygtighed højt, og dermed skabe en konkurrencefordel.

6. Sæsonbestemt Optimering af Affaldshåndtering

Ved at tilpasse affaldshåndteringen til sæsonbestemte affaldstyper, som fx solcremeflasker om sommeren og rødkålsemlage i december, kan affaldscentre effektivisere deres drift og derved optimere deres processer løbende. Dette kan føre til lavere omkostninger og forbedret affaldshåndtering over tid.

7. Udvikling af Datadrevne Produkter og Tjenester

De data, der indsamles gennem visionssystemet, kan anvendes til at udvikle yderligere tjenester, som fx analyser og prognoser for affaldsstrømme, der kan sælges til producenter, kommuner og forskningsinstitutioner. Dette giver mulighed for at skabe en ny forretningsgren baseret på data og analyse.

Ovennævnte aspekter peger på et stort forretningspotentiale inden for affaldshåndtering, som kan generere indtægter og samtidig fremme bæredygtighed og effektivitet i branchen.

Bilag 1. Brugervejledning - Robot

Bilag 1.1 Brugervejledning

Der er udarbejdet følgende brugervejledning:

Brugervejledning

Opstart

- Inden systemet startes, skal der sikres, at der ikke er nogen, som kan komme i nærheden af robotten.

Herefter udføres følgende handlinger:

1. Tænd for **ABB Robot Controller** og sæt **operation mode** til **auto**.
2. Bekræft at **døren til robotten** er lukket.
 1. Sørg for at døren er lukket.
 2. Nulstil dørsensoren ved at trykke på den blå knap til venstre for døren.
3. Bekræft at døren er lukket på **ABB FlexPendant** (**Acknowledge Superior Stop open**).
3. Sørg for at **Timing Controller**, **Vision/Robot Controller** er tændt (det bør de altid være):
 - Tænd for **Timing Controller** etc. ved at tænde for strøm til elskab med **Timing Controller**.
 - Tænd for **Vision/Robot Controller**.
5. Start **Vision/Robot Controller**:
 1. Log ind i Windows via touch-skærmen på toppen af elskabet.
 2. Start **PlasticWasteSorter**-programmet som ligger på skrivebordet i Windows.
6. Tryk **Start** i **user interface**.

Herefter vil robotten efter kort tid efter bevæge sig hen til en startposition og være klar.

Nedlukning

1. Stop **Vision/Robot Controller**:
 1. Log ind i Windows via touch-skærmen på toppen af elskabet.
 2. Tryk **Stop** i **user interface**.
 3. Luk **PlasticWasteSorter**-programmet ved at trykke på X.
2. Sluk for **ABB Robot Controller**.

Error: Robot outside work area

Hvis fejlmeldingen "Robot outside work area" vises på **ABB FlexPendant** skal følgende procedure følges.

1. Sæt *operation mode* til **manual** på **ABB Robot Controller**.
2. Tryk på **ABB** - **Jogging** på **ABB FlexPendant**.
3. Brug joystick til bevæge robotten til en central position over båndet
4. Sæt *operation mode* til **auto** på **ABB Robot Controller**.
5. Bekræft skift til *auto* *operation mode* på **ABB FlexPendant**.
6. Luk og start programmet **PlasticWasteSorter**

ABB Robot Controller

- Enheden tændes/slukkes ved at dreje den store afbryder på fronten.
- Enhedens *operation mode* vælges ved at dreje nøglen på frontpanelet.
 - **Auto mode** er et cirkulært mønster,
 - mens **manual mode** har et symbol, der forestiller en hånd.


Hvis enhedens *operation mode* er ændret fra **manuel** til


auto, skal dette valg bekræftes på **ABB FlexPendant**.

Bilag 1.2 Emneliste

Alle emnerne er fremvist nedenfor på den mørke baggrund, men der er undersøgt reflektans-spektra for alle emner med både en mørk og en lys baggrund.

TABEL 12. Emneliste.

Emne	Type	Farve	Baggrund
	PP	Grå	Mørk
	HPDE	Hvid/transparent	Mørk
(uden wrap og cap)			
	PVC	Hvid	Mørk
	PP	Rød	Mørk

Emne	Type	Farve	Baggrund
	HDPE	Hvid	Mørk
	N.A	Multifarvet	Mørk
	PET	Transparent	Mørk
	PET	Grøn	Mørk
	PET	Blå	Mørk

Emne	Type	Farve	Baggrund
	ABS	Flerfarvet	Mørk
	PS	Transparent/hvid	Mørk
	Polycarbonat		Mørk
	Polycarbonat		Mørk
	LDPE	Hvid	Mørk

Emne	Type	Farve	Baggrund
	Gruppe 7		Mørk
	PET – clear	Grøn/transparent	Lys, Mørk
	PET – clear	Transparent	Lys, Mørk
	PET – clear	Blå/Transparent	Lys, Mørk
	PET	Sort	Lys, Mørk
	PET	Sort	Lys, Mørk

Bilag 1.3 Liste over virksomheder fra IFAT 2024

Herunder er en oversigt over virksomheder som IHFood var i kontakt med under vores besøg på IFAT 2024.

- [BANO Recycling SRL](#)
- [Stadler](#)
- [Bollegraaf Recycling Solutions](#)
- [Sutco RecyclingTechnik GmbH](#)
- [Next Generation Recyclingmaschinen GmbH](#)
- [ATM Recyclingsystems GmbH](#)
- [Weima Maschinenbau GmbH](#)
- [ZenRobotics](#)
- [MAX AI](#)
- [Tomra](#)
- [Greyparrot](#)
- [RTT Steinert](#)

- [Recco Non Ferro Metals B.V.](#)
- [PreZero Stiftung & Co. KG](#)
- [Anker Andersen A/S](#)
- [HSM GmbH + Co.KG](#)
- [Komptech GmbH](#)
- [Fraunhofer-Institut für Umwelt-, Sicherheits- und Energietechnik UMSICHT Institutsteil](#)
- [Interzero Holding GmbH & Co. KG](#)
- [Senro B.V.](#)
- [Vezzani SpA](#)
- [WTT - Waste Treatment Technologies Netherlands B.V.](#)
- [Beston Group Co., Ltd.](#)
- [Machinex Industries Inc.](#)

Circular AI

Projektet "Circular AI" er støttet af Miljø- og Ligestillingsministeriets Miljøteknologisk Udviklings- og Demonstrationsprogram (MUDP), som har til formål at fremme udvikling og anvendelse af miljøeffektive løsninger på prioriterede miljøudfordringer og understøtte vækst og beskæftigelse.

Projektet om genanvendelse af sorte fødevarebakker, som også er et generisk projekt til højere genanvendelse af plastik i almindelighed, er gennemført i perioden 2022-2024.

Projektet viser at ved brug af avancerede AI- og maskinlærings-algoritmer, herunder anvendelse af computer vision baseret primært på neurale netværk og avancerede annoteringsværktøjer, kan man udvikle et system, der kan detektere, kategorisere og sortere plasttyper, selv komplekse materialer såsom sorte fødevarebakker som tidligere har udgjort en væsentlig udfordring. En udvikling som vil gøre det mere rentabelt og dermed mere attraktivt at indsamle plastik.

Hvert år bliver der indsamlet 84.000 tons plastaffald i Danmark, men kun 42% af dette bliver genanvendt. Der er derfor langt til EU's mål om 65% genanvendelse i 2035. En af de store udfordringer er detektion og korrekt sortering af plast, herunder sort plast, hvilket især benyttes til fødevareplast samt plast til rengøring, personlig hygiejne og kosmetik.



Miljøstyrelsen
Tolderlundsvej 5
5000 Odense C

www.mst.dk