



## KAF – Årsrapport 2018

Automatisk produkt-ID med kvalitetstjek

1. marts 2019  
Proj.nr. 2006249  
Version 1.5  
PESG/MT

Peter René Bolvig Stentebjerg

### Indledning

Projektets rammer er beskrevet i ansøgningen til Kvægafgiftsfonden 2018

### Problemstilling

Sortering af produkter fra udbeningslinjen til pakkeriet foregår typisk vha. operatører, der manuelt identificerer den specifikke produkttype, hvorefter produktet automatisk sendes til den korrekte pakkelinje for vakuumering. Operatøren skal kunne skelne mellem flere produkttyper, men ellers er arbejdet præget af en gentagende procedure, der lægger op til automatisering.

### Formål

Formålet med projektet er at afdække de teknologiske muligheder for at kunne foretage produktgenkendelse vha. visionteknologi. DMRI råder over et multispektralt visionudstyr, der giver en platform, og en erfaring til at kunne gennemføre udviklingen af dette projekt. Hovedformålet bliver dermed at udvikle software, som skal foretage den automatiske genkendelse af produkterne. Til dette benyttes et selvlærende neuralt netværk, der udnytter den nyeste teknologi indenfor Deep Learning. Derudover kan løsningen også benyttes til at detektere fremmedlegemer på produktoverfladen for at kunne vurdere kvaliteten af produkterne.

*Værtsslagteri & applikation*

### Værtsslagteri

I samarbejde med et værtsslagteri indenfor kvægslagting kunne DMRI tidligt i projektet vurdere projektomfanget og klarlægge den konkrete applikation, som omfavner problemstillingen og samtidig viser en fordel i at automatisere produktgenkendelsen.

Det blev også besluttet ikke at montere visionudstyret i produktionen pga. pladsmangel samt manglende projektmidler til at løse pladsproblemer. I stedet vedtog man, at dataopsamlingen ville foregå over en periode, hvor DMRI ville være til stede til manuelt at opsamle datamateriale af hovedparten af den produktvariation, som produceres ved udbeningslinjerne.

### Applikation & krav

Aktuelt foretages udbeningen på 2 linjer, hvor slutproduktet for enden af linjerne skal identificeres og sendes til den korrekte pakkestation. På begge linjer står en operatør og foretager identifikationen samt indtaster denne til systemet, der sikrer korrekt transport af produktet til pakkelinjen. Derudover benyttes der yderligere en operatør til manuelt at adskille og flytte produkter fra et roterende opsamlingsbord for enden af udbeningslinjen til et infeed bånd, hvor den anden operatør foretager genkendelsen og destinerer produkterne til pakkelinjerne. Det betyder, at denne proces kræver 2 operatører nogle steder i udbeningen. Kravene til løsningen kan hermed formuleres med følgende punkter:

- Udstyret skal kunne indpasses i produktionen, så en automatisering vil bidrage til et bedre arbejdsmiljø samtidig med en effektivisering af processen.
- Der kan spares operatørtid, ideelt set minimum 1 fuld operatørbemanding.
- Kvaliteten i sorteringen skal som minimum være på samme niveau, men helst bedre.
- Løsningen skal have en tilbagebetalingstid på typisk 2-3 år i forhold til businesscasen.

### Dataopsamling

Forudsætningen for en valideret algoritmeudvikling af en automatisk genkendelse vha. Deep Learning er mange data, dvs. billeddata af produktvariationen indenfor de valgte produkttyper. Det var derfor formålet med dataopsamlingen at få 500-1000 billeder af mange forskellige produkter målt fra flere sider, hvor dette er relevant. Under hver produkttype indgår der desuden forskellige alderskategorier som fx kalv, ungkvæg og okse. Før dataopsamlingen fandt sted, blev udstyret opdateret med en ny softwareplatform, der kunne adskille produkter på bånd til selvstændige billeder, samt en mulighed for at brugeren kunne angive produktets ID. Dermed kunne man under dataopsamlingen opbygge et referencedatasæt af billeder med tilsvarende ID, som kan benyttes til at oplære genkendelsesmodellen, der opbygges med en Deep Learning-algoritme.



Eksempler på billeddata for 2 produkttyper (striploin & mørbrad)



Billede fra dataopsamling med visionudstyr foretaget på slagteriet

*Hvad er Machine Learning, Neurale Netværk og Deep Learning?*

### **Machine Learning**

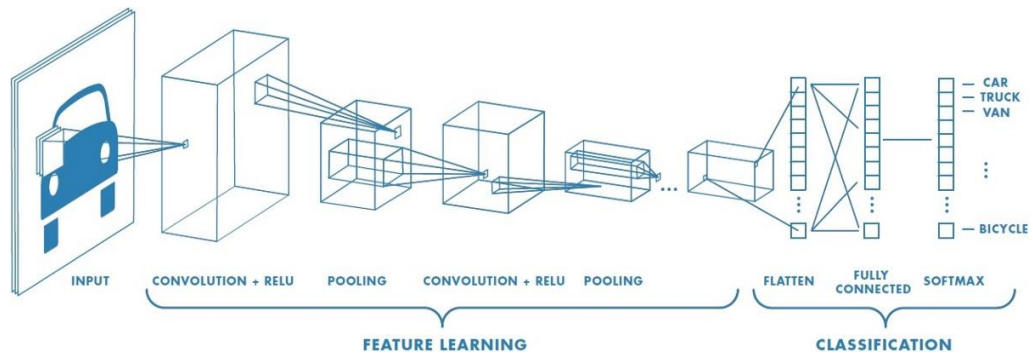
Machine Learning er et bredt begreb, men i bredeste forstand er målet at udnytte regnekraften i moderne computere til at skabe algoritmer, der er mere præcise og robuste, end det der kan udføres af mennesker.

### **Neurale Netværk**

Kernen i de fleste Machine/Deep Learning-metoder til billedanalyse er et kunstigt neuralt netværk. Inspirationen er biologiske neurale netværk, som består af nerveceller, neuroner og signaludveksling mellem neuronerne. Det kunstige neurale netværk består af knudepunkter (svarende til neuroner) organiseret i flere lag, som repræsenterer hver sin funktion, fx "registrering af lodrette eller vandrette kanter i et billede". Registreringen af den givne karakteristik danner input til næste lag af nodes (signaludveksling), og når et netværk trænes, fastlægges, hvor stor vægt hver enkelt karakteristik skal have for at opnå den endelige beskrivelse af billedet.

### **Deep Learning**

Deep Learning er meget store neurale netværk med mange lag imellem input og output. Før udbredelsen af Deep Learning indenfor billedklassifikation, udvalgte/genererede mennesker de forventede relevante features, og algoritmen blev trænet på disse features. Den store fordel ved Deep Learning indenfor billedanalyse er, at pga. netværkets størrelse og specielle lagtyper, kan netværket gennem træning finde frem til de relevante features. Det betyder samtidig, at Deep Learning-metoder er meget afhængige af datakvaliteten, fordi det ikke er mennesker, der holder netværket i hånden.



Skitse over opbygningen af et neuralt netværk med Deep Learning

Anvendelse af Neurale Netværk er ikke ny i slagterisektoren, idet man påbegyndte anvendelsen til klassificering af svin og kvæg allerede i midten af 90'erne, fx i KKC-2. De moderne Deep Learning-modeller, der anvendes i dag, er mere komplekse og kræver større computerkraft. Samtidig indeholder de mange flere lag i beregningerne og er i et vist omfang blevet mere tilgængelige at bruge og hurtigere at træne op.

*Databehandling & algoritmeudvikling*

### **Databehandling & opbygning af Deep Learning-netværk til automatisk genkendelse**

Referencematerialet fra dataopsamlingen blev rensset op, så fejlmålinger og andre forstyrrelser for genkendelsesmodellen blev fjernet.

Som Deep Learning-plattform er TensorFlow benyttet, hvilket danner rammen for et værktøj til at opbygge et Deep Learning netværk. Ved at benytte TensorFlow blev der opbygget algoritmer til at danne en genkendelsesmodel ud fra referencesættet af billeddata. Dette blev testet op mod et valideringssæt af utrænede billeder, som blev benyttet til at verificere genkendelsen.

### **Udvikling af algoritmer til fremmedlegemedetektion**

Referencedatasættet består af multispektrale billeddata indeholdende en ekstra nærinfrarød kanal udover standard RGB-kanaler. Med denne information kan algoritmer udvikles vha. billedanalyse til at detektere fremmedlegemer af små stykker farvet plast ud fra deres spektrale information i et billede.

*Resultater*

### **Resultat af den automatiske genkendelse med Deep Learning**

Resultatet af den automatiske genkendelse giver en gennemsnitlig procentsikkerhed på 97,7% på 20 forskellige produkttyper. Disse produkttyper kunne med fordel være yderligere opdelt efter tidligere nævnte alderskategorier, der måske kan forbedre performance af den automatiske genkendelse. Der er en derimod en anden mulighed for at øge genkendelsesraten ved at lade systemet frasortere billeder, som genkendelsesmodellen vurderer som usikre. Dette gør, at nogle billeder bør identificeres manuelt, men

til gengæld forekommer der færre fejl i identifikationen, som skal korrigeres ude ved pakkelinjerne. Fx kan der opnås et genkendelsesniveau på over 99% ved at frasortere knap 6% af billederne.

### **Resultat af kvalitetsvurdering i form af fremmedlegemedetektion**

Projektet har fået eksempler på flere forskellige plasttyper, der er repræsenteret i produktionen. Heraf viser analyseresultaterne, at der er en god detektionsrate af alle farvede plasttyper, som adskiller sig fra farverne i produktet. Kravet er kun, at plastikken er synlig på produktoverfladen. Udover dette kan der være udfordringer med meget transparente plasttyper, hvor farven fra produktet dominerer den spektrale information, idet plastikken bliver usynlig ved tæt kontakt til produktet. Det anbefales derfor ikke at benytte transparente plasttyper i produktionen.

### *Konklusion* **Konklusion & udbytte**

Projektet har demonstreret en løsning på den teknologiske udfordring med at automatisere identifikationen af en række produkttyper samt at kunne kontrollere overfladen for fremmedlegemer af farvede plastikstykker. Udbyttet af projektet vil give slagterierne mulighed for at spare 1 operatør på de linjer, hvor der aktuelt anvendes 2 operatører til opgaven, og dermed at kunne øge effektiviseringen. Hvis løsningen kan udbygges med en automatiseret udlægning af produkter på en række foran visionudstyret, fx via en robotløsning, kan den tilbageværende operatør aflastes. Derudover vurderes det også, at løsningen kan give en mere ensartet genkendelse af produkttyperne på tværs af operatører og slagterier, idet proceduren bliver automatiseret af en maskine og ikke flere mennesker. Den automatiske genkendelsesmodel er designet til de produkter, som den er trænet op til, dvs. flere typer af produkter med interne variationer i forhold til skæringen. Fremtidige produkttyper skal manuelt registreres af en operatør, hvorefter de kan indgå i en udvidelse af den generelle genkendelsesmodel, der vil opdatere løsningens performance.