



## Notat

7. december 2018  
2006150-02-01  
TMO,DBN,GLN,EVO

### Testrapport - metode

Deep learning algoritme i billeddannende måleudstyr til måle- og klassificeringsanvendelser i fødevarevirksomheder.

#### *Introduktion*

Vision teknologi vil blive brugt i utallige sammenhænge i fremtiden. Fremtidens førerløse biler er helt afhængige af vision og ikke mindst en hurtig analyse af billederne. Det er muliggjort af hurtige computere og ikke mindst smarte algoritmer. Algoritmerne er ikke afhængige af den aktuelle problemstilling, hvorfor de også vil kunne anvendes på problemstillinger indenfor fødevareproduktion. Den mest lovende teknologi er Deep learning, TI/DMRI's arbejde med metode og test af denne teknologi er beskrevet nedenfor.

#### *Machine learning*

##### ***Hvad er deep learning?***

Machine learning er et bredt begreb, men i bredest forstand er målet at udnytte regnekraft i moderne computere til at skabe algoritmer, der er mere præcise og robuste end hvad der kan skabes af mennesker alene. En Machine learning metode består i at træne neurale netværk til at genkende de kategorier, man er interesseret i.

#### *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 (svarer til neuroner) organiseret i flere lag, som repræsenterer hver sin funktion, for eksempel "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 enkel 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 data kvaliteten, fordi der ikke er mennesker, der holder netværket i hånden.

#### *Eksempel ImageNet*

ImageNet Challenge er et billedgenkendelses datasæt, der består af 1.2 mio billeder i høj opløsning, som er klassificeret i 1000 forskellige klasser, for eksempel billeder, hvor der er en bil med på billedet, en hund, et menneske osv. Et netværks performance på ImageNet datasættet bruges i dag som en målestok for, hvor godt netværket er. ImageNet er også interessant, fordi man her for første gang så potentialet ved dybe neurale netværk. I 2012 blev det første dybe neurale netværk anvendt i denne konkurrence, hvor det slog nærmeste konkurrent med 10 procentpoint i præcision, hvilket på daværende tidspunkt var helt uhørt.

#### **Hvornår er metoden anvendelig?**

#### *Karakteristik af egnede problemstillinger*

Deep learning er velegnet til problemstillinger, hvor der er mange billeder af det samme fænomen, som for eksempel slagtekroppe på en slagtelinje, og hvor mennesker er i stand til at gruppere fænomenet/billederne i forskellige klasser. I disse tilfælde vil metoden være en billig og præcis løsning.

#### **Eksempel på succesfuld anvendelse**

#### *Diagnostik*

Diagnostisering af mange sygdomme baseres på røntgenbilleder, hvor erfarne læger er i stand til at identificere for eksempel lungebetændelse. Et studie, hvor en Deep learning model er trænet på 100.000 røntgenbilleder, klassificeret med hensyn til 14 lungesygdomme, resulterede i færre falsk positive og falsk negative diagnosticeringer end det tilknyttede lægeteam leverede.

#### **Faldgruber**

#### *Mangelfulde data*

Der findes en række eksempler på nettet, hvor den automatiske algoritme har resulteret i meget uheldige løsninger. I alle disse tilfælde skyldes det utilstrækkelige mængder data, ikke tilstrækkelig repræsentative data, ukorrekte reference-klassificeringer, annoteringer eller et datasæt, som præsenterer et forvredet billede af virkeligheden.

#### **Software**

#### *TensorFlow*

TensorFlow er et open source Deep learning framework udviklet af Google. Brugeren kan justere vægtingen af hver node med

## Alternativer

henblik på at opnå den bedste performance. TensorFlow har mange indbyggede biblioteker til for eksempel forbehandling af billeder, og da det er baseret på open source framework findes mange eksempler på implementering.

Der findes en lang række alternative løsninger, hvor de fleste også er open source produkter. Størst af disse er Pytorch, udviklet af Facebook, som også har oplevet en eksplosiv vækst indenfor det sidste år.

TensorFlow er valgt fordi det er det mest fleksible af de kendte frameworks og samtidig har det overhalet ældre frameworks i popularitet på kort tid, især i forhold til produktionsklare systemer.

### Testmetode

Metoden testes med hensyn til dens egnethed til at klassificere målinger/billeder indenfor fødevarereproduktion. Testen består af fire dele:

1. Genberegning af et problem fra en slagtelinje analyseret med IBMs Watson software.
2. Sammenligning med Machine learning – få grupperinger
3. Klassificering af mange grupper
4. Klassificering på pixel-niveau af billeder, der er vanskelige at annotere

### Test 1. Genberegning af Watson-eksemplet

En slagterivirksomhed stillede en problemstilling til rådighed for test af IBM's Watson software, idet IBM fik adgang til at optage en række billeder inklusiv en ekspert-klassificering/annotering. Samme datasæt blev stillet til rådighed for TI/DMRI med henblik på test med TensorFlow. Billedmængden var begrænset, nemlig kun 300 (150 gode og 150 dårlige). Billederne skulle først forbehandles, idet baggrund og omgivelser skal fjernes, så kun produkter er tilbage i synsfeltet. Derefter blev algoritmen trænet med samme klassifikationssikkerhed, som Watson algoritmen.

Figur 1.  
Illustration af behovet for forbehandling af billedet, så det kun er produktet, som analyseres.




*Test 2.  
Halebid – Machine learning vs deep learning*

Diagnosticering af halebid er anvendt til at vise effekten af Deep learning vs. Machine learning. Den første analyse af billederne bestod i at beskrive de forskellige typer læsioner for eksempel areal og afstand fra halespids og dernæst træne en model med disse input-variable og +/- læsion som referencevariabel. Metoden gav knapt 70% korrekt klassificerede.

Dernæst blev en Deep learning algoritme fastlagt, som umiddelbart øgede andelen af de korrekt klassificerede til 80%. Til sidst blev en Deep learning algoritme, som på forhånd var trænet på ImageNet billederne, tilpasset den aktuelle problemstilling, hvilket øgede de korrekt klassificerede til 89%.


*Figur 2.  
Klassificering af halebid.*



*Test 3.  
Produkttyper – klassificeringsproblemer*

Ovenstående eksempler har kun omfattet en gruppering i god og dårlig. I det næste eksempel skal produktbetegnelsen af indholdet i kasser fastlægges. Her er udfordringen, at der er flere produktbetegnelser end selv en trænet slagter kan genkende, hvorfor den endelige løsning skal kombineres med ekstra information for eksempel om produktet er fra økologiske grise eller fra varianter af det samme hovedprodukt. Ensartetheden indenfor den samme produkttype er ligeledes en udfordring, idet kasserne kan være mere eller mindre fyldte. Endelig er det en udfordring at få en ligelig repræsentation af alle typer. Alligevel er det lykkedes at opnå 98% korrekt klassificering i 29 klasser.

*Figur 3.  
Eksempel på problemstilling med mange klasser.*



*Test 4.  
Gødningrester – pixel-  
klassificering* Det sidste testeksempel er også klassificering i mange klasser, faktisk helt ned på pixelniveau. Eksemplet er fra arbejdet med at supplere veterinærkontrollens kontrol af gødningsforurening på slagtekroppen med et visionsystem. Her er udfordringen, at selv meget små forureninger er uacceptabelt. Endvidere er annoteringen en udfordring, da det kan være vanskeligt at skelne forurening fra slagtekroppen med hensyn til farve og kontrast.

*Konklusion* Test 1-4 viser, at det er muligt at anvende Deep learning algoritme til at fremstille de ønskede måleresultater fra billeddannende måleudstyr til klassificeringsanvendelser i fødevarevirksomheder.

### **Slutbemærkning**

*Instituttets egne erfaringer* Teknologisk Institut, DMRI, udviklede i 1990'erne et automatisk udstyr, et Klassificeringscenter, til klassificering af

*Klassificeringscenter til griseslagtekroppe* griseslagtekroppe, baseret på nær-infrarød lysrefleksionsprofiler opnået med prober, der blev stukket ind i slagtekroppen. Profilerne, syv i alt, viste refleksionen fra spæk og kød i op til 10 cm tykkelse syv steder på kroppen. Profilerne kan opfattes som billeder og et meget enkelt neuralt netværk fastlægger spæk- og kødtykkelser som input til beregning af slagtekroppens totale kødindhold. Udstyret var det mest præcise udstyr i en lang årrække.

*Klassificeringscenter til kreaturslagtekroppe* Parallelt med ovenstående udvikledes et klassificeringsudstyr, KKC2, til kreaturslagtekroppe. Det er baseret på rigtige billeder, hvor især konturen og farverne er vigtige karakteristikker. Formålet er at klassificere slagtekroppe efter kroppens form og fedme ligesom en klassificeringsekspert vil gøre. Dette eksempel ligner de problemstillinger, hvor Deep learning er egnet som løsningsmetode.

### *Referencer*

- 1 Præsentation på temamøde 26. november 2018  
<https://www.teknologisk.dk/40144>
- 2 Analyse af produkter fra slagtelinjen, der anvendes til at sammenligne med resultaterne fra IBMs. Billeddata samt modeller: <Y:\Organization\C028\540 Dataanvendelse\DC Horsens billeder>

*Deltagere* Troels Thorsen Mørch  
Dennis Brandborg Nielsen  
Glenn G. Brink Nielsen  
Eli Vibeke Olsen