


Utvärdering och integration av GAN (Generative Adversarial Networks) som neuralt nätverk för detekterande av avvikelser genom bildanalys utav kognitiva kameror för kvalitetssäkring i produktionslinjer

Publik rapport



Författare: [Gimic AB](#)
Datum: [2019-07-23](#)
Projekt inom [Elektronik, Mjukvara och Kommunikation](#)

Innehållsförteckning

Sammanfattning	3
Executive summary in English	4
Bakgrund	4
Syfte, forskningsfrågor och metod	5
Mål	5
Resultat och måloppfyllelse	5
Spridning och publicering	8
Kunskaps- och resultatspridning	8
Slutsatser och fortsatt forskning	8
Deltagande parter och kontaktpersoner	8
Referenser	9

Kort om FFI

FFI är ett samarbete mellan staten och fordonsindustrin om att gemensamt finansiera forsknings- och innovationsaktiviteter med fokus på områdena Klimat & Miljö samt Trafiksäkerhet. Satsningen innebär verksamhet för ca 1 miljard kr per år varav de offentliga medlen utgör drygt 400 Mkr.

För närvarande finns fem delprogram; Energi & Miljö, Trafiksäkerhet och automatiserade fordon, Elektronik, mjukvara och kommunikation, Hållbar produktion och Effektiva och uppkopplade transportsystem. Läs mer på www.vinnova.se/ffi.

1 Sammanfattning

Gimic AB tillhandahåller kognitiva kameror som används för kvalitetsavsyning inom tillverkningsindustrin, Hordagruppen är vår referenskund som är en underleverantör av formblåsta produkter till fordonsindustrin. Med hjälp av machine learning identifierar kamerorna produkter och bedömer dess kvalité, för att i realtid instruera en robot om en produkt är defekt och i så fall ska sorteras bort.

Gimic's lösning använder idag CNN (Convolutional Neural Networks) vilket funkar mer än tillfredsställande, men nya typer av neurala nätverk som GAN (Generative Adversarial Networks) visar väldigt lovande resultat och detta med träning enbart baserad på *normal data*. Med en implementation som AnoGAN (Anomaly GAN) behöver man i teorin sålunda inte tillhandahålla *dålig data* vid träning utav modeller, utan nätverket beräknar avvikelser av osedda bilder. Detta vill vi undersöka och utvärdera då ett eliminerande av behovet utav bilder av diverse defekta produkter radikalt skulle förenkla och förbättra träningen av modellerna, så till den grad att kund själv (enbart med hjälp av referensbilder) skulle kunna ombesörja träningen för sina produkter på Gimics molnplattform.

I den initiala studien visade sig det dock finnas begränsningar i ett tredjepartsramverk som Gimics edge-plattform använder sig av, som gjorde det omöjligt att använda AnoGAN som planerat. Istället gjordes studien på en kategori av neurala nätverk som kallas "Siamese networks", som erbjuder samma fördelar som AnoGAN, d.v.s. att dålig data inte behövs för att träna upp en modell.

Utvärderingen av Siamese-nätverk visade att dessa är ett mycket gott alternativ till CNN-nätverk inom vissa användningsområden där avsyningsobjektet är fixerat.

Som en del av projektet implementerades stöd i Gimics molnplattform för att hantera olika typer av ML-modeller. Det byggdes även stöd för slutanvändare att själv hantera dataset och modeller, så att ingen extern kompetens behövs för detta.

För vidare forskning önskar vi i framtiden återkomma till att utvärdera AnoGAN. I och med att området utvecklas oerhört fort är det mycket möjligt att ramverksstödet har kommit ifatt inom kort, och att det därigenom blir möjligt att använda den typen av modeller i Gimics produkter med en rimlig arbetsinsats.

2 Executive summary in English

Gimic AB is a supplier of cognitive cameras used for quality inspection in the manufacturing industry. Using machine learning models the camera evaluates the quality of a product, and can send a signal in realtime to a robot if the product is defective and thus should be discarded.

Gimic's solution today uses CNN (Convolutional Neural Network) models, which works very well, but new types of neural networks such as GAN (Generative Adversarial Networks) shows very promising results using training data based on "normal" product images only. We want to investigate and evaluate using one of these models, since eliminating the need for training data for defective products would greatly simplify the dataset handling & model training workflow for the end user.

In the initial phase of the study we discovered limitations in a third-party framework used on Gimic's edge platform, which made it impossible to support GAN networks for now. Instead we decided to investigate another category of neural network called "Siamese networks". These give the same benefits as GAN's, so that training data for "bad" products is not needed to train a model.

The evaluation phase for Siamese networks showed that these are a very good alternative to CNN's for certain use cases where the position for the inspected object is fixed.

As a part of the project we also implemented support in Gimic's cloud platform to easily handle different types of Machine learning models.

For further research we wish to return to evaluating AnoGAN in the future. As the area develops extremely fast, it is very possible that the framework support has been caught up shortly, and that it will thus be possible to use those types of models in Gimic's products with a reasonable work effort.

3 Bakgrund

Gimic AB producerar kognitiva kameror för kvalitetsavsyning inom tillverkningsindustrin, med primär inriktning på formblåsning. Med hjälp av machine learning identifierar våra kameror produkter och bedömer dess kvalitet, som ett proaktivt steg för att säkerställa att defekta produkter identifieras och elimineras i ett så tidigt skede som möjligt. Defekta produkter riskerar skada utrustning, orsaka produktionsstopp och i värsta fall levereras till kund vilket går att undvika med Gimics kameror.

Gimics nuvarande generation av kameror använder neurala nätverk av typen CNN (Convolutional Neural Networks) för klassificering av bilder. CNN kan ses som en de facto standard idag för bildigenkänning och detektering av avvikelser, men nya akademiska publikationer (se referens 1 och 2) påvisar att den nya neurala nätverkstypen GAN presterar till och med bättre än CNN och detta med träning på enbart *bra data*. Detta vill vi undersöka, utvärdera och använda inom träningen av modellerna så att en kund själv med enbart referensbilder på bra produkter kan tillgodose all den nödvändiga test-datan. Detta skulle

eliminera i princip all komplexitet i dagens träning och möjliggöra att kunden själv utför detta moment som idag kräver expertkunskap, och om avhandlingarna om GAN stämmer så ökar dessutom kvalitén på avsyningen.

4 Syfte, forskningsfrågor och metod

Projektet syftade till att undersöka möjligheten att använda alternativa ML-modeller för automatisk detektering av avvikelser i produktionslinjer.

Ett delmål i detta var att göra Gimics grundplattform mer flexibel så att det går snabbare att komma igång med nya modelltyper, när forskningen visar att ett bättre alternativ finns att tillgå.

Ett tredje mål med projektet var att utveckla en prototyp till ett GUI, där slutanvändaren själv kan skapa dataset och träna de modeller som sedan kan användas i produktionslinjen.

I projektet användes en klassisk agil utvecklingsmetodik, där utvecklingsteamet byggde ny funktionalitet i korta implementationscykler. Återkoppling från projektparterna inhämtades kontinuerligt under projektets gång.

5 Mål

Projektets mål definierades inom tre grova områden i ansökan:

- Undersöka om det finns alternativa ML-modeller som kan tränas utan dålig data som är ett fullgott alternativ till de CNN-nätverk som används idag.
- Implementera stöd för en ny modell av typen som beskrivs ovan, och utvärdera denna mot motsvarande CNN-modell
- Implementera mjukvarustöd för slutkund att själv hantera träningsdata och träna modeller i Gimics molnplattform Cotton.

6 Resultat och måluppfyllelse

Enligt projektbeskrivningen innehöll projektet 3 faser: "prototyp", "träning" och "produktionssättning".

I prototyp-fasen utvecklades stöd för att hantera & träna olika typer av machine learning-modeller i Gimics molnplattform "Cotton". På grund av tekniska begränsningar i ML-ramverket som används på Gimics edge-plattform valde vi efter en förstudie att inte använda GAN-nätverk, utan istället använda en annan typ av nätverk med liknande egenskaper som kallas "Siamese networks" (se referens 3 och 4).

Siamese-nätverk har samma fördelar gentemot CNN-nätverk som GAN har, dvs de kräver enbart bilder på "bra" produkter för träning av modeller. I och med att fördelarna för

slutanvändaren blir de samma ansågs bytet till Siamese-nätverk vara en implementationsdetalj som inte påverkade projektplanen eller värdet för den potentiella slutkunden.

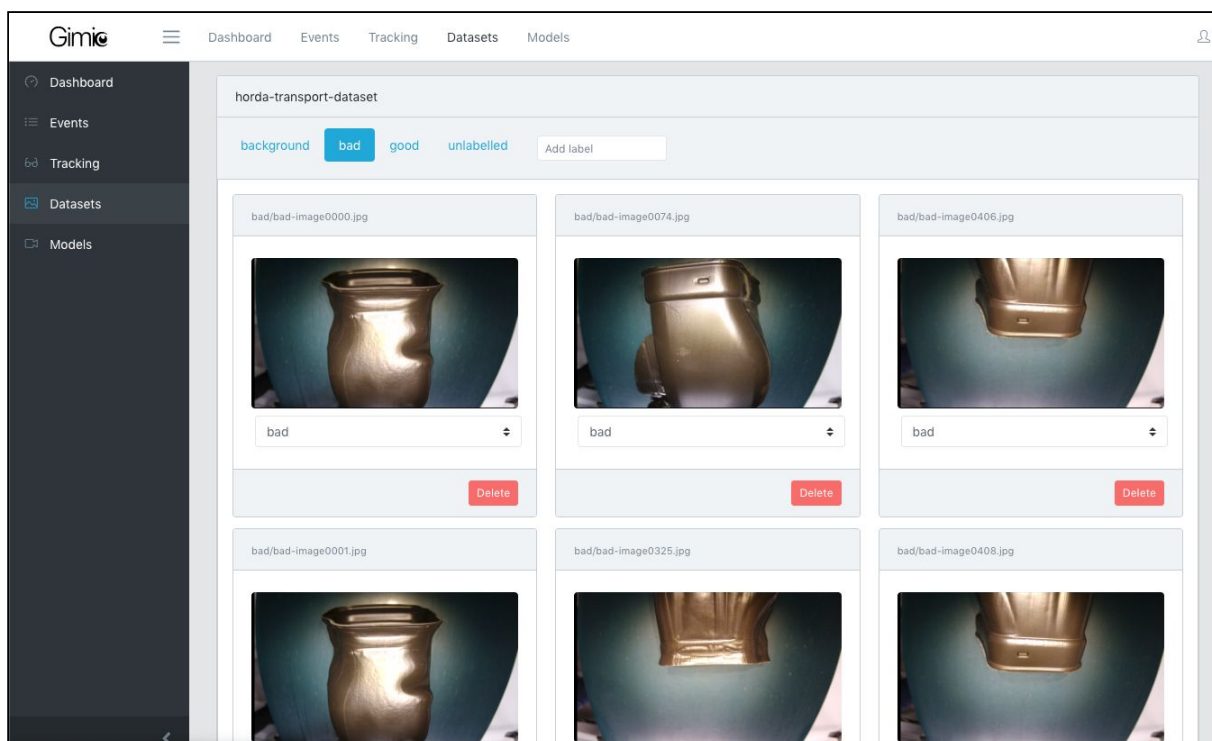
Vid utvärderingen av Siamese-nätverken visade det sig att dessa lämpar sig mycket väl för vissa användningsfall, där en produkt kan fixeras och fotas i samma position varje gång vid avsyningen. Både felprocent och utnyttjad GPU/CPU-tid för avsyning var jämförbar med motsvarande CNN-nätverk, men med den stora fördelen att datasetet för träning kan vara mycket mindre och inte behöver innehålla bilder på dåliga exemplar.

Utdata från ett Siamese-nätverk skiljer sig från data som kommer från ett klassificerings-nätverk. Vid klassificering är utdata från nätverket en kategori ("bra", "dålig", "katt", "hund" osv), samt en sannolikhet på hur säker nätverket är på att kategoriseringen är rätt. I Siamese-nätverket är istället utdata en siffra som visar hur mycket bilden som skickats genom nätverket avviker från en referensbild. Hur stor denna avvikelse är och hur gränsen för vad som är dåligt och vad som är bra ska sättas beror på vilken modell som tränats, och kräver en del experimenterande för att få rätt.

Avvikelsen ger också en möjlighet att säga något om **hur** mycket en produkt avviker från det ideala, vilket är en mycket eftertraktad egenskap. För klassificering kan nätverket säga att en produkt är dålig och hur stor sannolikheten är att den har rätt, men sannolikheten i sig är egentligen inte jämförbar mellan olika avsyningar. Som exempel kan en produkt som klassificeras som dålig med 95% sannolikhet objektivt sett vara "bättre" än en produkt som klassificerades som dålig med 85% sannolikhet. Som kontrast till detta ger avvikelse-måttet från Siamese-nätverket faktiskt en jämförbar enhet som kan användas för att avgöra hur kvaliteten utvecklas över tid i produktionen.

På grund av de goda egenskaperna hos Siamese-nätverken som beskrivs ovan kommer dessa i framtiden vara standardvalet som modell i våra stillbildskameror, medans vi kommer fortsätta använda de redan existerande CNN-nätverken för avsyning där objektet rör sig, t.ex. på ett löpande band. Detta beror på att Siamese-nätverken behöver en referensbild på hur den felfria produkten ska se ut, vilket gör att den inte är lika förlåtande som CNN-nätverk för objekt som rör på sig och befinner sig på olika positioner under avsyningsprocessen.

I träningsfasen utvecklades även GUI-stöd i molnplattformen för slutanvändaren att själv hantera dataset & modeller. Detta har testats av medarbetare på Horda och har fått mycket positiv feedback.



Bilden ovan visar ett dataset från Hordagruppen i Gimics webbportal.

Produktionssättningsfasen i projektet är något försenad jämfört med planen, och är nu planerad att ske i slutet av september 2019. Detta beror på längre ledtider än förväntat i kommunikationen mellan Gimic & Horda samt vissa problem i hårdvaran i nästa generations edge-plattform som nu är lösta.

7 Spridning och publicering

7.1 Kunskaps- och resultatspridning

Hur har/planeras projektresultatet användas och spridas?	Markera med X	Kommentar
Öka kunskapen inom området	X	
Föras vidare till andra avancerade tekniska utvecklingsprojekt	X	
Föras vidare till produktutvecklingsprojekt	X	
Introduceras på marknaden	X	
Användas i utredningar/regelverk/tillståndsärenden/ politiska beslut		

8 Slutsatser och fortsatt forskning

Resultaten från projektet visar att det finns goda alternativ till klassiska CNN-modeller för automatisk avsyning i produktionslinjer.

I detta projekt analyserades och implementerades en lösning baserat på "Siamese networks", men det finns andra intressanta typer av nätverk i samma kategori som vi planerar att undersöka framöver. AnoGAN-nätverk var t.ex. med i den ursprungliga planen för projektet men som fick utgå på grund av saknad teknisk funktionalitet i det ramverk som används i Gimics plattform. Vi ser fram emot att återkomma till detta område vid en senare tidpunkt när ramverken har hunnit ifatt den akademiska utvecklingen.

9 Deltagande parter och kontaktpersoner

Gimic AB - Marcus Nilsson
Hordagruppen AB - John Lejon

10 Referenser

1: "Unsupervised Anomaly Detection with Generative Adversarial Networks to Guide Marker Discovery" - <https://arxiv.org/pdf/1703.05921.pdf>

2: "ANOMALY DETECTION WITH GENERATIVE ADVERSARIAL NETWORKS" - <https://openreview.net/pdf?id=S1EfyIZ0Z>

3: Siamese Neural Networks for One-shot detection of Railway Track Switches - <https://arxiv.org/pdf/1712.08036.pdf>

4: Siamese Neural Networks for One-shot Image Recognition - <https://www.cs.cmu.edu/~rsalakhu/papers/oneshot1.pdf>