

OMVÄRLDSBEVAKNING - MÖJLIGGÖRANDE ELEKTRONIK & MJUKVARA

TEMA Deep Learning



Detta är en omvärldsbevakning som genomförs inom FFI fokuserande på möjliggörare inom elektronik och mjukvara. Avsikten är att inspirera produktutveckling och forskning relaterad till svenskt näringsliv till nya innovationer.

Temat i denna utgåva av omvärldsbevakningen är "Deep learning" som senaste tiden överträffat äldre metoder för att ta fram specialiserade algoritmer. Det typiska exemplet för fordon är objektidentifiering i ADAS eller automatiserad körning, men flera andra exempel tas upp i denna omvärldsbevakning som spänner från produktion till trafikledning.

Som vanligt utgår omvärldsbevakningen från rapporter och annan publicerad information i vår omvärld, framförallt utanför Sverige.

Innehåll:

Hot News2

- GPU teknologi i fordon
- Smart ratt
- Intrång i självkörande fordon

Arkitektur i smarta fordon och smarta infrastrukturer.....3,4,5,6,7,8

- Vad är deep learning
- Kort historik, vad är nytt?
- Autonoma fordon och deep learning
- Deep learning i fordonsproduktion
- Deep learning förbättrar modeller
- Framtidens förartjänster
- Diagnos och underhåll
- Fleet management och trafikledning
- Mycket beräkningskraft vid träning, mindre vid användning
- Köpa eller utveckla? Hur kommer Deep Learning att användas
- Vad bör vi vänta oss i framtiden?

**HOT
NEWS:**



GPU teknologi kommer i fordon

NVIDIA ser automotive som en framtidsbransch för företagets GPU teknologi. Enligt keynote på CES i Shanghai kommer flera NVIDIA teknologier i Audi modeller de närmsta åren.

NVIDIA:s automotive blog:

<http://blogs.nvidia.com/blog/category/auto/>

NVIDIA på CES:

<http://blogs.nvidia.com/blog/2015/06/03/audi-nvidia-ces-asia/>

Smart ratt

Sensorer för övervakning av förarens beteende presenteras i ökande mängd. Ett nytt koncept presenteras av Krippner Inc. där man har foliebaserade sensorelement integrerade i ratten för att detektera förarens beteende.

http://www.automotive-eetimes.com/en/built-in-steering-wheel-sensors-ward-off-driver-s-hand-slip.html?cmp_id=7&news_id=222904320&vID=8

Intrång i självkörande fordon

Sensorer som används i självkörande bilar är många gånger känsliga för intrång ur ett säkerhetsperspektiv. Mission secure har gjort en intressant fallstudie där man också föreslår några rudimentära lösningar för att förbättra säkerheten.

http://www.missionsecure.net/wp-content/uploads/2015/03/Mission-Secure-TOMMYCAR_CASE_STUDY_3_23_15.pdf

TEMA Deep Learning



Vad är deep learning?

Deep Learning är en form av maskininlärning, dvs en teknologi för att beräkna modeller av datamängder givet ett antal exempel på datapunkter. Modellerna kan sedan användas för olika tillämpningar inom analys, styrning, prediktion, med mera. Låt oss som enkel illustration anta att vi har datapunkter för fastighetsaffärer, bostadsytor och försäljningspriser. Vi kan rita in dessa i ett diagram och dra en rät linje som visar ett statistiskt samband. Med den linjen som modell kan vi förutsäga ungefär vad ett hus av en viss storlek kan kosta. Maskininlärning bygger på samma princip men kan hantera mycket stora mängder data och beräkna högdimensionella icke-linjära modeller som representerar komplexa samband och har många olika tillämpningar.

Deep Learning låter oss arbeta med långt större och mer avancerade modeller än tidigare metoder. En enda modell kan ha miljarder parametrar och tränas att representera strukturerad kunskap med stor detaljnivå även för mycket komplexa data, givet tillräckligt stort antal exempel. Vi kan träna en sådan modell på exempel av bilder och texter som beskriver dem och få en funktion som kan beskriva en alldeles ny bild. Vi kan träna en modell på exempel av inspelat talat språk och den text det motsvarar och få en funktion som tolkar tal till text. Sådana inlärda modeller överträffar och ersätter nu specialiserade teknologier för dessa problem som utvecklats och förfinats av mänskliga experter under decennier.

Deep Learning kan givetvis också användas på data från industriella system, processer och produkter, och ge oss nya kraftfulla funktioner som även de överträffar och ersätter traditionella lösningar och skapar helt nya möjligheter. Vi diskuterar flera exempel nedan.

Kort historik, vad är nytt?

Deep Learning är ett exempel på ett så kallat artificiellt neuronät eller neuralt nät, som inspirerats av hjärnans funktion men är enklare och mindre än de biologiska. Neurala nät har utvecklats steg för steg under många decennier, genomgått perioder av uppblåsta förväntningar, för att sedan bli en standardkomponent i verktygslådan för maskininlärning. Fram till nyligen har andra metoder oftast varit att föredra men Deep Learning har inneburit en revolution. Genom förfinade metoder, exponentiellt större tillgänglig beräkningskraft i takt med Moores lag och med mycket mer träningsdata har vi kunnat träna större och större neurala nät som steg för steg överträffar och tränger undan andra metoder, både specialiserade algoritmer för specifika problem och andra generella maskininlärningsmetoder.

Denna omvärldsbevakning skulle helt kunna fyllas av exempel på Deep Learning som slagit världen med häpnad och trissat upp



priserna på företag med expertis och lösningar till astronomiska höjder, men vi nöjer oss med ett: Företaget DeepMind visade 2014 hur ett Deep-Learning-system kan lära sig att spela ett flertal olika Atari-tv-spel genom att prova sig fram med kontrollerna och själv titta på skärmbilden. Det köptes strax därefter av Google för 500 miljoner dollar.

Autonoma fordon och Deep Learning

Flera internationella forskningscentra med kompetens inom robotik och autonoma system har på senare år startat nära samarbeten med fordonstillverkare för utveckling av autonoma fordon inom en rad områden [4,5]. Fokus är inte främst autonoma personbilar, som ju redan drivs aktivt av många aktörer, utan andra typer av industriella fordon där reduktion av mänsklig styrning och inblandning är önskvärd. Exempelvis utvecklas inom jordbruket helautomatiska fordon för skördning, inventering och monitorering av skog samt inom gruvnäringen autonoma kräv- last- och dumpermaskiner. Inom gruvnäringen används halvautomatiska fordon i kombination med fjärrstyrning, så kallad "assisted mining", med framgång i miljöer som är hälsofarliga och oåtkomliga för människor. Många beslut måste tas direkt av fordonet som är utrustat med speciella kameror och lokal beräkningskraft.



Deep Learning och maskininlärning ingår som nyckelkomponent i flera centrala delar av dessa system. Detta sker främst inom bildbehandling för att känna igen specifika objekt som hinder, diken, med mera, och för att kunna identifiera och varna för kritiska situationer där människor finns. Modellerna tränas på applikationsspecifika data på servermaskiner med hög kapacitet och kan sedan kompakteras för att användas effektivt lokalt i fordonet.

Deep Learning i fordonsproduktion

Deep Learning har potential att påverka fordonsproduktionen på i huvudsak två sätt: (1) förbättrad automation och (2) bättre modeller för att ge återkoppling till produktionsledet från analys av driftdata och dokumenterad användarupplevelse. Automationen kan dels förbättras genom att robotar genom Deep Learning ges förmågan att hantera situationer som tidigare inte har analyserats eller setts [4], dels genom att låta robotar lära sig nya rutiner genom att observera och analysera mänskliga rörelser, andra robotar eller video där nya rutiner spelas upp [5]. För det andra fallet finns ännu inget direkt exempel från fordonsindustrin dokumenterat, men Range Rover designade och producerade sin prisvinnande modell Evoque (2012) från grunden genom modellering och simuleringar baserat på insamlade av massiva datamängder från drift, användare och fordon. Deep Learning kan användas för att utöka en sådan analys genom till exempel prediktion av kundbehov genom analys av fritext på internet.

Deep Learning förbättrar modeller

Såväl inom kommersiell trafik som i samhällsplanering fattas många beslut med direkta konsekvenser för kostnader, trafiksäkerhet, miljö och infrastruktur. Detta inkluderar val av fordon, rutter och hastighetsprofiler längs givna sträckor. Flera av de existerande modellerna för beslutsunderlag har begränsningar. Det kan röra sig om inaktuell eller ofullständig data (t ex OD-matriser baserade på intervjuer eller optiska observationer), förenklande antaganden (i bränsleförbrukningsmodeller eller i modeller för flervillkorsoptimering) eller till naturen osäkra modeller (till exempel statistisk extrapolation från ett antal datapunkter). Under senare år har tillämpning av Big-Data-teknik inom fordons- och trafiksektorerna lett till förbättrade modeller för exempelvis bränsleförbrukning och underhållsbehov med mera [9]. Deep Learning kan på liknande sätt ytterligare förbättra existerande modeller. Ett exempel från fordonsindustrin är i Audis självkörande fordon, där fordonet inte bara har lärt sig att undvika hinder, utan har även lärt sig att förstå hinder från ett mer abstrakt och begreppsligt perspektiv. Detta medför att modelleraren inte behöver lära modellen alla typer av hinder - modellen upptäcker dem av sig själv, även sådana hinder som modelleraren inte hade förutsett. NVIDIA har utvecklat kretsen Tegra X1 för att stödja användningen av Deep Learning för objektigenkänning och bildanalys i ADAS-tillämpningar (Advanced Driver Assistance Systems) [2]. Systemet kommer att användas av Audi och Tesla i bland annat autopiloter [3].

Framtidens förartjänster

Framtidens fordon kommer att ha helt nya sätt att interagera med sin förare. Integrerade röst- och bildgränssnitt spås utgöra en central del i styrning och planering samt i hantering av externa tjänster som mail, sms och media. Maskininlärning blir en central komponent i dessa system för att hantera stora mängder av information under varierande förhållanden. Deep Learning är den idag enskilt mest effektiva metoden för att analysera bilder och mänskligt tal. Apples talstyrda tjänst Siri och liknande tjänster från Google, Baidu med flera baseras redan på Deep Learning. Fordon kommer i allt större grad ha integrerade röstsystmer för hantering av fordonets funktioner. Bilden ovan visar en applikation där systemet lärt sig känna igen ett antal objekt och även läsa av deras hastighet i relation till det egna fordonet.

Diagnos och underhåll

En annan trend är att maskininlärning kommer krävas för att analysera data från det snabbt ökande antalet sensorer i fordon. Dessa kan användas för att tidigt identifiera även små avvikelser, t ex försämring i prestanda. I takt med sjunkande priser på olika typer av sensorer kommer allt fler fordon att instrumenteras i detalj och övervakas på nya sätt. Redan idag finns produkter på marknaden som proaktivt varnar för fel genom att analysera stora mängder mätdata som spelas in när fordonen är i drift [7].



En fördel med Deep-Learning-modeller är att de i princip ger bättre resultat ju mer data och fler variabler man matar in vilket reducerar behovet av domänexperter som kan tala om vilken data som är mest relevant.

Fleet management och trafikledning

Flera tjänster som realtidsmonitorering och dirigerings av trafik kommer i allt högre grad automatiskt lära sig vilka mönster som är viktiga för att kunna förutse trafikstockning. Även här kommer komplexiteten i data kräva att mer av modelleringsarbetet sker automatiskt med hjälp av Deep Learning. Med lokal beräkningskapacitet i fordonen och ökande tillgänglighet på sensordata kan fler beslut också tas autonomt. I många tillämpningar och miljöer behöver man dock samordna flera fordon för synkronisering och dirigerings. Även här kan Deep Learning spela en viktig roll. Genom att tränas på många olika situationer kan de identifiera och larma om kritiska situationer i komplexa dynamiska system uppstår, till exempel tidiga tecken på köbildning. I dagsläget finns produkter baserat på Deep Learning riktade mot hantering av flockar av autonoma drönare [8]. Den form av tidsberoenden som uppstår i sådana system hanteras bland annat med en typ av återkopplade neuronnät som kallas RNN (Recurrent Neural Networks) vilka med framgång använts för att hitta mönster i flera typer av ostrukturerade dataserier.

Mycket beräkningskraft vid träning, mindre vid användning

Enorm mängder beräkningskraft och massiva datamängder är definierande egenskaper för Deep Learning. Det krävs mycket minne för att lagra representationen, mycket beräkningskraft för att lära sig den från data, och stora mängder exempel för att representationen skall bli bra. Hittills har de flesta riktigt framgångsrika exempel på Deep Learning använt stora datacenter eller ett mindre antal snabba, specialiserade och GPU-accelererade maskiner, men i takt med att Deep Learning och liknande tekniker ökat i popularitet har hårdvarulösningarna blivit mer tillgängliga: NVIDIA har tagit fram specialiserad hårdvara för Deep Learning (<https://developer.nvidia.com/devbox>), än så länge enbart för forskare men det är troligt att det ändras snart, och Amazon erbjuder snabba, NVGPU-accelererade maskiner som tjänst (<http://aws.amazon.com/hpc/>). Behovet av beräkningskraft för Deep Learning kvarstår, men det finns bra lösningar på marknaden. Den begränsande faktorn blir istället tillgången till data.

Det är dock värt att notera att det oftast är just träningen som är riktigt beräkningstung, inte att använda en tränad Deep-Learning-lösning. Det krävs många exempel och mycket beräkningskraft för att lära sig att känna igen objekt i en bild, men inte särskilt mycket för att sedan känna igen objekt i en ny bild. Vi kan använda framtagna Deep-Learning-lösningar i bilar, i robotar och i telefoner, men som regel inte träna dem där.

Köpa eller utveckla? Hur kommer Deep Learning att användas?


Deep Learning kommer med ett löfte om lärande system som enkelt och effektivt kan bygga bra representationer av världen utan nästan något manuellt modelleringsarbete. Som exemplen ovan visar ligger det en del i detta, men konstruktionen och kalibreringen av Deep-Learning-metoder för nya data och tillämpningar kräver erfarenhet och djup förståelse för maskininlärning. Just nu dammsuger företag som Google, Facebook och Baidu marknaden på specialister inom Deep Learning. Deras tjänster är oerhört dataintensiva och den här typen av teknologier kommer att vara helt avgörande för deras konkurrenskraft inom bara några år. Vi förutspår att de kommer att bli kritiska för all industri, alla produkter, alla tjänster, all produktion med potential för ökat värde genom automatisk analys och automatiskt beslutsfattande baserade på data. Med möjligheterna till mätning och styrning genom Internet of Things kommer få eller inga verksamheter vara undantagna.

Om ett företag idag vill utveckla egna lösningar för Deep Learning krävs en signifikant satsning på kompetens och utveckling, men detta kommer att förändras i takt med att tillgängliga implementationer och mjukvarubibliotek förbättras. Det är också troligt att Deep Learning inte bara kommer att vara en del av många färdiga tjänster och produkter, utan att vi kommer att se mer eller mindre färdiga komponenter på marknaden för generella tillämpningar som objektigenkänning i bilder eller sentimentanalys. Det kommer på sikt att bli mycket lättare att använda Deep Learning som en del av en produkt och även att utveckla egna Deep-Learning-baserade lösningar, även om det senare kommer fortsatt att kräva signifikant investering och kompetens.

Vad bör vi vänta oss i framtiden?

Ökad automation och autonomi genomsyrar idag såväl produkter och tjänster som produktion och produktutveckling. Här kommer Deep Learning och andra storskaliga maskininlärningsmetoder att spela en allt större roll och utvecklingen accelererar. Vi har redan mycket bra lösningar för vissa typer av data och uppgifter, som objektidentifiering i bilder, och ser nu även tillämpningar där kombinationer av flera typer av data kan representeras i samma modell, som bilder och text. Vi ser idag stora framgångar för neuronätsmodeller och kommer framöver med stor sannolikhet även att se vidareutveckling av andra typer av storskalig inlärning baserade på andra typer av modeller, exempelvis statistiska modeller och modeller utvecklade för naturligt språk.

Deep Learning är moget att tas i bruk i flera typer av tillämpningar idag och verktygen för att utveckla och träna djupa neuronät blir snabbt bättre. Inom fem år kan vi vänta oss att de är standardkomponenter för ett flertal specifika uppgifter inom exempelvis bildbehandling, taligenkänning och textanalys, och att



[Sverker Janson](#),
[Daniel Gillblad](#),
[Björn Bjurling](#),
[John Ardelius](#);
 alla på SICS
 Swedish ICT bidrog
 med sakkunskaper
 och textproduktion
 för Deep Learning

många ledande företag tagit Deep-Learning-modeller i bruk som är specialanpassade för deras eget produkt- och processdata, till exempel sensoravläsningar i fordon och GPS-data för en lastbilsflotta. På längre sikt kommer Deep Learning och relaterade tekniker med största sannolikhet att vara centrala i alla former av automation och intelligenta system.

Vi kan också vänta oss att dessa system ersätter allt mer mänskligt arbete i organisationer. Exemplet med bildanalys visade hur ett lärande system kan förstå och analysera bilder bättre än specialiserade algoritmer utformade av mänskliga experter. Ett annat område som kommer att påverkas i närtid är modellering och analys av data från produkter och processer, som exempelvis mobilitet, kund- och fordonsbeteenden, där lärande system snabbt överträffar enklare statistiska modeller och manuell hantering.

Även om det inte är rimligt att tro att alla företag har möjlighet att bygga upp egen spetskompetens inom Deep Learning så är det av stor vikt att följa och förstå utvecklingen och vart den leder på kort och lång horisont. Många produkter och arbetssätt kommer att förändras i grunden.

Referenser

1. <http://www.autonews.com/article/20150323/OEM06/303239979/audi-obstacle-and-a-lesson-in-creating-self-driving-cars>
2. http://automotive.eetimes.com/en/how-will-deep-learning-change-socs.html?cmp_id=7&news_id=222904182&vID=35
3. http://fourtitude.com/news/Industry_News_3/powered-tegra-x1-drive-px-auto-pilot-drive-cx-cockpit-computers-deliver-computer-vision-deep-learning-unprecedented-graphics-cars/
4. <http://www.nrec.ri.cmu.edu/>
5. <http://automotive.stanford.edu/>
6. <https://technology.ihs.com/427146/>
7. <http://www.dti.com.au/>
8. <http://www.neurala.com/>
9. [Omvärldsbevakningen Nov 2013 om Big Data för Fordon](#)