

Litteraturöversikt på området artificiell intelligens

Underlag till ramprojektrapport *Hur kan staten främja
användandet av digitaliseringens möjligheter i
näringslivet?*

Skreven av Fredrik Heintz docent vid Linköpings universitet



Dnr: 2016/011

Myndigheten för tillväxtpolitiska utvärderingar och analyser
Studentplan 3, 831 40 Östersund
Telefon: 010 447 44 00
Fax: 010 447 44 01
E-post: info@tillvaxtanalys.se
www.tillvaxtanalys.se

För ytterligare information kontakta: Irene Ek
Telefon: 010-447 44 79
E-post: irene.ek@tillvaxtanalys.se

Vad är artificiell intelligens?

Artificiell intelligens (AI) kan beskrivas som system som kan ta in data, se sammanhang samt fatta beslut och agera utifrån dessa. Ofta pratar man om system som känner av omgivningen, tar fram en plan för att uppnå sitt mål och sedan utför denna plan (Sense-Plan-Act) (Russel and Norvig, 2009). I många fall kan sådana system även lära sig av data som ingår i systemet. Ett vanligt program utför aktiviteter utifrån en uppsättning givna instruktioner, så kallade algoritmer. Ett självlärande system kan genom erfarenhet själv modifiera sina algoritmer (E. Brynjolfsson & McAfee, 2017a).

Ett exempel är Googles AI-bolag DeepMind som utvecklat mjukvara som heter AlphaGo och spelar det kinesiska brädspelet Go¹. År 2015 besegrade AlphaGo den främsta mänskliga Go spelaren (Silver et al 2016). Det nya är att Google nu utvecklat ett självlärande system som kallas AlphaGo Zero. AlphaGo Zero har slagit sin företrädare AlphaGo i 100 matcher av 100. Det som är speciellt med AlphaGo Zero är att programmet inte har lärt sig spela genom att analysera hur människor spelat tidigare utan genom att spelat mot sig själv (Silver et al 2017). AlphaGo har sedan även lärt sig spela schack (Silver et al 2017). Samma tekniker har även använts av Google för att minska kostnaderna för att kyla deras datacenter med 40% (Evans och Gao, 2016).

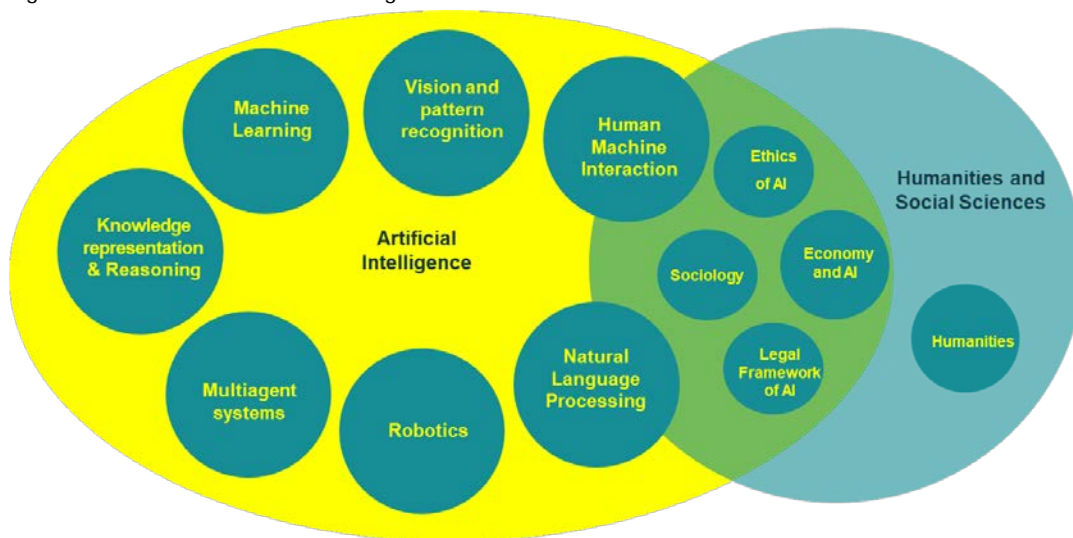
Forskningsöversikt

Artificiell intelligens är forskningsområdet som studerar hur man kan få datorer att göra saker som vi människor anser kräver intelligens som att planera, lösa problem, förstå naturligt språk, och lära oss nya saker (Russel and Norvig, 2009). Eftersom det är omtvistat vad intelligens verkligen är så fokuserar man ofta på system som beter sig intelligent utan att påstå att de verkligen är intelligenta. Vad mänsklig intelligens är och hur den fungerar studeras framför allt inom det närliggande forskningsområdet kognitionsvetenskap². Där är man ofta intresserad av att skapa algoritmer eller program som bygger på modeller av hur mänskliga kognitiva funktioner fungerar. Det vanliga inom AI är annars att man skapar algoritmer och program som uppvisar ett intelligent beteende utifrån datavetenskapliga principer snarare än kognitionsvetenskapliga eller neurovetenskapliga, även om det kan finnas en biologisk inspiration. Ett klassiskt exempel är på biologisk inspiration är artificiella neuronnät (ANN) som är en kraftigt förenklad modell av hur neuronerna i hjärnan fungerar som sedan implementeras i en dator huvudsakligen som matrisoperationer (Hubel and Wiesel 1962, Rummelhart, et al 1986).

¹ <https://deepmind.com/research/alphago/>

² <https://plato.stanford.edu/entries/cognitive-science/>

Figur 1 Områden inom artificiell intelligens



Källa: Presentation av Danica Kragic, Fredrik Heintz och Daniel Gillblad på WASP konferensen AI4X Education & Entertainment Introduction februari 2018

AI har många underområden som studerar olika delar av intelligent beteende. Den största internationella AI-konferensen IJCAI³ listar t.ex. följande områden: maskininläring, sökning, planering, kunskapsrepresentation, slutsatsdragning, villkorlösning, förståelse av naturligt språk, robotik, perception och multiagentsystem. Alla dessa områden har studerats sedan mitten på 50-talet då AI-området skapades. De två viktigaste delområdena har varit kunskapsrepresentation och slutsatsdragning (knowledge representation and reasoning) samt maskininläring (machine learning). Inom kunskapsrepresentation studerar man hur kunskap kan representeras av en dator. Inom slutsatsdragning studerar man hur man kan dra giltiga slutsatser från observationer, kunskap och annan information. Inom maskininläring studerar man hur en dator kan lära sig saker som att hitta mönster, känna igen föremål, eller agera för att uppnå specifika mål.

Idag är det framför allt maskininläring som fått stor uppmärksamhet. Den förra AI-vågen som var som starkast på 80-talet handlade mycket om expertsystem som skulle kunna fånga mänsklig kunskap och agera som ett intelligent beslutsstöd. Förväntningarna är ungefär de samma idag, men teknikerna annorlunda och det är fullt rimligt att det faktiskt kommer lyckas betydligt bättre den här gången.

Sverige har av tradition varit väldigt starka inom kunskapsrepresentation, slutsatsdragning, planering och robotik. Idag håller många på med maskininläring där vi har en uppåtgående trend. Några områden vi är kända för är obemannat flyg (Doherty et al 2014; Marconi et al 2017; Simoense et al 2018), grasping (Bohg et al 2014; Hang et al 2016), människa-robot-interaktion (Bütepage och Kragic 2017; Doherty et al 2011; Kristoffersson et al 2013; Ziemke et al 2017), planering (Doherty et al 2013; Kvarnström 2011; Warnquist et al 2016), och maskininläring för robotik (Andersson et al 2017; Ghadirzadeh et al 2017).

Traditionellt har AI handlat mycket om att automatisera uppgifter som kräver intelligens. Då det troligen är relativt få saker som kommer automatiseras helt, så kommer intresset och vikten av människa-AI-interaktion sannolikt öka stadigt.

³ <http://www.ijcai-18.org/>

Det är viktigt att komma ihåg att ett AI inte kan tänka i mänsklig bemärkelse och att de nästan uteslutande kan en och endast en sak. De är inte på något sätt generella som vi människor (Johnson, 2018; Gooman, etal. 2014).

Maskininlärning

Maskininlärning kan delas in i tre områden: övervakad inlärning (supervised learning), oövervakad inlärning (unsupervised learning) och återkopplingsinlärning (reinforcement learning). De allra flesta tekniker som används inom industrin idag är av typen övervakad inlärning. Utifrån en stor samling exempel på indata och motsvarande förväntade utdata kan dessa algoritmer skapa antingen en klassificerare, dvs en funktion som sätter en etikett på varje möjlig indata, eller en godtycklig funktion som uppskattar det förväntade svaret givet indata. Exempel på tekniker är t.ex. djupinlärning (deep learning), regression, och Bayesianska metoder (Bishop 2011; Goodfellow etal 2017; James etal 2013).

Enligt Andrew Ng, en av världens ledande AI-forskare, så skapas mest värde genom övervakad inlärning, där det har funnits två vågor av framsteg. Den första, möjliggjorde att förutsäga om en användare kommer klicka på en annons utifrån information om användaren. Den andra, kan hantera betydligt mer komplexa svar som en mening på ett annat språk än det som sades.⁴

Djupinlärning är troligen den teknik som fått mest uppmärksamhet. Ett artificiellt neuronätverk bestående av flera lager kan approximera en godtycklig funktion. De började studeras redan på 50-talet. Dock kunde man inte träna upp nätverk med mer än två lager förrän backpropagation uppfanns i mitten på 80-talet (Rumelhart etal 1986). Faltningsnätverk (convolutional neural networks) som kan hantera att saker, t.ex. ett föremål i en bild, kan finnas lite var som helst i bilden uppfanns några år senare (LeCun etal 1990). Att det tog drygt 20 år innan de slog igenom beror på att det krävs dels väldigt många exempel och dels väldigt stora beräkningsresurser. Det stora genombrottet kom med AlexNet (Krizhevsky etal 2012) som slog alla andra metoder i att känna igen bilder i ImageNet (Deng etal 2009) efter ett antal stegvisa framsteg (LeCun etal 1998; Bengio etal 2006; Hinton etal 2006; Glorot etal 2011). Rawat och Wang (2017) har skrivit en aktuell översikt över djupinlärning för bildigenkänning.

En annan kraftfull form av ANN är återkopplade ANN (recurrent neural network) som tillåter nätverket att lära sig känna igen sekvenser (Hochreiter etal 1997). Ett område som utvecklats mycket tack vare dessa metoder är att översätta och förstå naturligt språk (Bengio etal 2001; Sutskever etal 2014).

Återkopplingsinlärning fungerar genom att programmet känner av vilket tillstånd det är i, fattar ett beslut om vilken handling som ska utföras och sedan får den en omedelbar återkoppling på hur bra/dåligt det gick. Den generella idén är att försöka göra mer av det som leder till positiv återkoppling och undvika de handlingar som leder till negativ återkoppling. Återkopplingsinlärning har använts en hel del inom robotik (Kober etal 2013) men även för att lära en dator att spela Atari-spel (Mnih etal, 2015) och Go (Silver etal 2017) i nästan alla fall kombinerat med djupinlärning. Tekniken är generell och väldigt attraktiv, men många utmaningar återstår⁵.

⁴ <http://knowledge.wharton.upenn.edu/article/ai-new-electricity>; <https://hbr.org/2017/10/how-to-spot-a-machine-learning-opportunity-even-if-you-arent-a-data-scientist>; <https://hbr.org/2016/11/what-artificial-intelligence-can-and-cant-do-right-now>

⁵ <https://www.alexirpan.com/2018/02/14/rl-hard.html>

Även om framgångarna med djupinlärning för uppgifter som att spela spel, sätta etiketter på föremål i bilder och översätta naturligt språk finns det många utmaningar. Några är att lära sig mer generella representationer (Bengio et al 2013), att undvika att ANNs blir för specifika (Srivastava et al 2014), att förklara varför ett ANN ger en viss rekommendation så kallade eXplainable AI (Gunning 2017), att lära ett nätverk flera olika saker (Caruana 1997), att kombinera inlärning med slutsatsdragning (Khardon och Roth 1997; Bottou 2014) och att kombinera inlärning och logik (Richardson och Domingos 2006). En aktuell och intressant fråga är om ett generellt ANN räcker eller om det krävs andra medfödda kunskaper, strukturer eller algoritmer för att lära sig allt som vi människor kan lära oss (Marcus 2018; Diettrich 2018)⁶.

Tillämpningar

AI har väldigt många och skiftande tillämpningar, allt från beslutsstöd till automatisering (Kearney et al 2017). Några exempel är:

Rekommendationssystem som de som Netflix och Spotify använder för att utifrån vad du tycker om och vad andra som liknar dig tycker om ge dig förslag på vad du troligen också kommer att gilla (Gomez-Uribe och Hunt 2016). The Netflix Prize var en av de första och största tävlingarna där ett företag gjorde ett dataset öppet och utmanade världen att hitta den bästa lösningen (Bennet och Stan 2007; Bell och Yehuda 2007). Lu et al (2015) har skrivit en aktuell översikt över rekommendationssystem.

Kundsupport, vanligtvis genom någon form av digital assistent (Silver et al 2013). Enligt Dilek Hakkani-Tur från Google så är nästa stora utmaning att förstå mening bortom orden. Till exempel, om en användare säger "senare idag" så kan det betyda mellan 7 och 9 om det handlar om middag eller mellan 3 och 5 om det handlar om ett arbetsmöte. Den här nästa nivån skulle möjliggöra betydligt mer komplexa konversationer som hoppar mellan olika domäner. Digitala assistenter borde även kunna sammanfatta texter och epost på ett enkelt sätt⁷.

Marknadsföring (Abe et al 2002) och försäljning. På många företag används AI för att öka försäljningen. Alibaba låter till exempel användare ladda upp bilder på saker de skulle vilja ha, som något de sett på stan, och sedan hittar de var man kan köpa saken billigast. Alibaba använder också förstärkt verklighet (augmented reality) för att låta kunderna få känslan av att gå i en affär samt titta och ta på sakerna de är intresserade av att köpa. En annan sak de jobbar mot är att kunna lägga in 3D-föremål i uppladdade filmer för att ytterligare öka försäljningen⁸.

Många av tillämpningarna bygger på att kunna klassificera indata. Nästa steg blir att kunna svara på frågor mer i stil med IBM Watson, så kallade frågor-svar-system (Question-Answering Systems) (Ferrucci, et al. 2010; Ferrucci, et al. 2013; Bordes et al 2014; Weston et al 2015).

En relaterad och stark trend är att gå från skriven text till talat språk (Collobert et al 2011; Hinton et al 2012). Här finns produkter som Amazon Alexa och Google Echo.

AI kan även användas för att skapa helt nya möjligheter, som att kunna skapa kedjor av utbyte av njurar, där man tidigare var tvungen att hitta ett passande par av donatorer kan man idag, tack vare AI, hitta kedjor av byten (Abraham et al 2007; Ashlagi et al 2015).

⁶ <https://wp.nyu.edu/consciousness/innate-ai/>

⁷ <http://knowledge.wharton.upenn.edu/article/ai-new-electricity>

⁸ <http://knowledge.wharton.upenn.edu/article/ai-new-electricity>

Det finns även många tillämpningar inom medicin och hälsa som medicinsk diagnos utifrån bilder (Litjens et al 2017) och att hitta nya läkemedel (Chen et al 2018).

Sammanfattningsvis kan man säga att alla tillämpningar som bygger på att klassificera saker eller att göra prediktioner utifrån data lämpar sig väldigt väl för AI/maskininlärning. Vi kommer troligen se en uppsjö av tillämpningar i alla samhällssektorer.

Att skapa värde med AI

För att skapa framgångsrika kommersiella applikationer med övervakad inlärning, krävs att den specifika funktionen som ska läras upp identifieras så precist som möjligt. Sedan måste man samla in, rensa och annotera lämplig träningsdata för uppgifter. Därefter kan man utvärdera olika algoritmer och inställningar för att se vilken kombination som ger de bästa modellerna enligt de fastställda utvärderingskriterierna. Om resultatet inte blir tillräckligt bra så måste man samla in mer data, förbättra databehandlingsprocessen eller kanske välja en annan algoritm. Slutligen måste modellen integreras i produkten eller tjänsten på ett skalbart och underhållsbart sätt. Helst ska man även ha en process för hur man kan förbättra modellen allteftersom den används (Brynjolfsson och Mitchell, 2017).

Det vi ser växa fram är ett nytt sätt att programmera datorer på. Istället för att utifrån en analys av problemet ta fram en lösning så kan man genom att samla in en stor mängd exempel på vad systemet ska göra få fram ett program som approximerar dessa exempel så gott det går. För problem som är väldigt svåra att analysera, som att känna igen föremål i bilder eller tolka tal så kommer det här troligen få stort genomslag.⁹

Den här typen av lösningar fungerar bra där vi tydligt och klart kan specificera vad systemet ska göra och där vi kan avgöra om slutresultatet är rätt eller fel. Samtidigt så får vi människor en viktig roll att ställa rätt frågor och utvärdera om systemen gör rätt eller fel (Brynjolfsson och Mitchell, 2017).

Ett annat exempel är schack, där vi människor inte har haft en chans mot datorn de senaste 20 åren. Ändå ökar intresset för schack och kvalitén på schackspelarna ökar eftersom de tränar mot datorerna. Dessutom är det så att om man kombinerar människor och schackdatorer så är de bättre än både de bästa människorna och de bästa datorerna. Det handlar alltså inte om antingen människa eller maskin, utan både och. En intressant och viktig observation är att det är en annan färdighet att vara bra på att spela schack med datorhjälp jämfört med utan. Vi kommer alltså att behöva utbilda folk för att kunna lösa problem tillsammans med datorer. Jeannette Wing har argumenterat att datalogiskt tänkande (computational thinking), att lösa problem på ett sätt så att datorer kan hjälpa till, är en fjärde grundläggande färdighet efter läsa, skriva och räkna (Wing 2006)

⁹ Software 2.0, <https://medium.com/@karpathy/software-2-0-a64152b37c35>

Referenser

- Abe, N. et al. Empirical comparison of various reinforcement learning strategies for sequential targeted marketing. In *IEEE Int. Conf. Data Mining* 3–10 (2002)
- David Abraham, Avrim Blum, and Tuomas Sandholm. Clearing algorithms for barter exchange markets: Enabling nationwide kidney exchanges. In *Proceedings of the ACM Conference on Electronic Commerce (EC)*, pages 295-304, 2007.
- Olov Andersson, Mariusz Wzorek and Patrick Doherty. Deep Learning Quadcopter Control via Risk-Aware Active Learning. *Proceeding of AAAI*. 2017.
- Ashlagi, Itai, et al. "Mix and match: A strategyproof mechanism for multi-hospital kidney exchange." *Games and Economic Behavior* 91 (2015): 284-296.
- Bennett, James, and Stan Lanning. "The netflix prize." *Proceedings of KDD cup and workshop*. Vol. 2007. 2007.
- Bell, Robert M., and Yehuda Koren. "Lessons from the Netflix prize challenge." *Acm Sigkdd Explorations Newsletter* 9.2 (2007): 75-79.
- Bengio, Y., Lamblin, P., Popovici, D. & Larochelle, H. Greedy layer-wise training of deep networks. In *Proc. Advances in Neural Information Processing Systems* 19 153–160 (2006). This report demonstrated that the unsupervised pre-training method introduced in ref. 32 significantly improves performance on test data and generalizes the method to other unsupervised representation-learning techniques, such as auto-encoders.
- Bengio, Y., Ducharme, R. & Vincent, P. A neural probabilistic language model. In *Proc. Advances in Neural Information Processing Systems* 13 932–938 (2001). This paper introduced neural language models, which learn to convert a word symbol into a word vector or word embedding composed of learned semantic features in order to predict the next word in a sequence.
- Bengio, Y., Courville, A. & Vincent, P. Representation learning: a review and new perspectives. *IEEE Trans. Pattern Anal. Machine Intell.* 35, 1798–1828 (2013).
- Bishop, C. *Pattern Recognition and Machine Learning*. 2011.
- J Bohg, A Morales, T Asfour, D Kragic. Data-driven grasp synthesis—a survey. *IEEE Transactions on Robotics* 30 (2), 289-309. 2014.
- Bordes, A., Chopra, S. & Weston, J. Question answering with subgraph embeddings. In *Proc. Empirical Methods in Natural Language Processing* <http://arxiv.org.e.bibl.liu.se/abs/1406.3676v3> (2014).
- Bottou, L. From machine learning to machine reasoning. *Mach. Learn.* 94, 133–149 (2014).
- C. B. Browne et al., "A Survey of Monte Carlo Tree Search Methods," in *IEEE Transactions on Computational Intelligence and AI in Games*, vol. 4, no. 1, pp. 1-43, March 2012. doi: 10.1109/TCIAIG.2012.2186810
- Brown and Sandholm, *Libratus: The Superhuman AI for No-Limit Poker*, IJCAI 2017

- J Bütepage, D Kragic. Human-Robot Collaboration: From Psychology to Social Robotics. arXiv preprint arXiv:1705.10146
- Noam Brown and Tuomas Sandholm, Superhuman AI for heads-up no-limit poker: Libratus beats top professionals, *Science* Vol. 359, Issue 6374, pp. 418-424, Jan 2018
- Erik Brynjolfsson and Tom Mitchell. What can machine learning do? Workforce implications. *Science* Vol 358, Issue 6370, Dec 2017.
- Caruana, R. (1997). Multitask learning. *Machine Learning*, 28, 41–75.
- H. Chen, O. Engkvist, etc, The rise of deep learning in drug discovery, *Drug Discovery Today*, 2018
- Collobert, R., et al. Natural language processing (almost) from scratch. *J. Mach. Learn. Res.* 12, 2493–2537 (2011).
- J. Deng et al., Imagenet: A large-scale hierarchical image database. *Computer Vision and Pattern Recognition*, 2009. IEEE Conference on. IEEE, 2009.
- Diettrich, T. Reflections on Innateness in Machine Learning. *Medium* 2018.
<https://medium.com/@tdiettrich/reflections-on-innateness-in-machine-learning-4eebefa3e1af>
- Patrick Doherty, Fredrik Heintz and David Landén. A Delegation-Based Architecture for Collaborative Robotics. In Danny Weyns and Marie-Pierre Gleizes, editors, *Agent-Oriented Software Engineering XI*. 2011.
- Patrick Doherty, Fredrik Heintz and Jonas Kvarnström. High-level Mission Specification and Planning for Collaborative Unmanned Aircraft Systems using Delegation. *Unmanned Systems*, 1(1):75–119. World Scientific. 2013
- Patrick Doherty, Jonas Kvarnström, Mariusz Wzorek, Piotr Rudol, Fredrik Heintz and Gianpaolo Conte. HDRC3 - A Distributed Hybrid Deliberative/Reactive Architecture for Unmanned Aircraft Systems. In Kimon P. Valavanis, George J. Vachtsevanos, editors, *Handbook of Unmanned Aerial Vehicles*, pages 849–952. 2014.
- Evans, R. & Gao, J. Deepmind AI reduces Google data centre cooling bill by 40%.
<https://deepmind.com/blog/deepmind-ai-reduces-google-data-centre-cooling-bill-40/> (2016)
- D. Ferrucci, E. Brown, J. Chu-Carroll, J. Fan, D. Gondek, A.A. Kalyanpur, A. Lally, J.W. Murdock, E. Nyberg, J. Prager, N. Schlaefer, and C. Welty. Building Watson: An Overview of the DeepQA Project. *AI Magazine* 31(3), 59-79, American Association for Artificial Intelligence, 2010. <https://www.aaai.org/Magazine/Watson/watson.php>
- David A. Ferrucci, Anthony Levas, Sugato Bagchi, David Gondek, Erik T. Mueller. Watson: Beyond Jeopardy! *Artif. Intell.* 199, 93-105, 2013.
- A Ghadirzadeh, A Maki, D Kragic, M Björkman. Deep predictive policy training using reinforcement learning. *IEEE Intelligent Robots and Systems (IROS)*, 2017.
- Glorot, X., Bordes, A. & Bengio. Y. Deep sparse rectifier neural networks. In *Proc. 14th International Conference on Artificial Intelligence and Statistics* 315–323

- (2011). This paper showed that supervised training of very deep neural networks is much faster if the hidden layers are composed of ReLU.
- Ian Goodfellow, Yoshua Bengio and Aaron Courville. Deep Learning. 2017.
- Gomez-Uribe, Carlos A., and Neil Hunt. "The netflix recommender system: Algorithms, business value, and innovation." *ACM Transactions on Management Information Systems (TMIS)* 6.4 (2016): 13.
- Goeman, N., Tenenbaum, J. Probability, programs, and the mind: Building structured Bayesian models of cognition, Proceedings of the Annual Meeting of the Cognitive Science Society, 36(36), 2014
- D. Gunning, Explainable artificial intelligence (xai). Defense Advanced Research Projects Agency, DARPA/I20, (DARPA, 2017).
- K Hang, M Li, JA Stork, Y Bekiroglu, FT Pokorny, A Billard, D Kragic. Hierarchical fingertip space: A unified framework for grasp planning and in-hand grasp adaptation. *IEEE Transactions on robotics* 32 (4), 960-972. 2016
- Hinton, G. E., Osindero, S. & Teh, Y.-W. A fast learning algorithm for deep belief nets. *Neural Comp.* 18, 1527–1554 (2006). This paper introduced a novel and effective way of training very deep neural networks by pre-training one hidden layer at a time using the unsupervised learning procedure for restricted Boltzmann machines.
- Hinton, G. et al. Deep neural networks for acoustic modeling in speech recognition. *IEEE Signal Processing Magazine* 29, 82–97 (2012). This joint paper from the major speech recognition laboratories, summarizing the breakthrough achieved with deep learning on the task of phonetic classification for automatic speech recognition, was the first major industrial application of deep learning.
- Hochreiter, S. & Schmidhuber, J. Long short-term memory. *Neural Comput.* 9, 1735–1780 (1997). This paper introduced LSTM recurrent networks, which have become a crucial ingredient in recent advances with recurrent networks because they are good at learning long-range dependencies.
- Hubel, D. H. & Wiesel, T. N. Receptive fields, binocular interaction, and functional architecture in the cat's visual cortex. *J. Physiol.* 160, 106–154 (1962).
- Gareth James, Daniela Witten, Trevor Hastie and Robert Tibshirani. *An Introduction to Statistical Learning with Applications in R*. 2013.
- Johnson, C. Do Computers Really Think? CACM2018
- A.T. Kearney Analysts, Evans, H., Hu, M., Kuchembuck, R., Gervet, E., Will you embrace AI fast enough?, 2017
- Kharon, R., & Roth, D. (1997). Learning to reason. *Journal of the ACM*, 44(5), 697–725.
- Jens Kober, J. Andrew Bagnell, Jan Peters, Reinforcement learning in robotics: A survey, *International Journal of Robotics Research* 2013
- A Kristofferson, S Coradeschi, A Loutfi. A review of mobile robotic telepresence. *Advances in Human-Computer Interaction* 2013
- Krizhevsky, A., Sutskever, I. & Hinton, G. ImageNet classification with deep convolutional neural networks. In *Proc. Advances in Neural Information Processing Systems* 25 1090–1098 (2012). This report was a breakthrough that used

- convolutional nets to almost halve the error rate for object recognition, and precipitated the rapid adoption of deep learning by the computer vision community.
- Jonas Kvarnström. Planning for Loosely Coupled Agents Using Partial Order Forward-Chaining. Proc. ICAPS 2011.
- LeCun, Y. et al. Handwritten digit recognition with a back-propagation network. In Proc. Advances in Neural Information Processing Systems 396–404 (1990). This is the first paper on convolutional networks trained by backpropagation for the task of classifying low-resolution images of handwritten digits.
- LeCun, Y., Bottou, L., Bengio, Y. & Haffner, P. Gradient-based learning applied to document recognition. Proc. IEEE 86, 2278–2324 (1998). This overview paper on the principles of end-to-end training of modular systems such as deep neural networks using gradient-based optimization showed how neural networks (and in particular convolutional nets) can be combined with search or inference mechanisms to model complex outputs that are interdependent, such as sequences of characters associated with the content of a document.
- G. Litjens et al., A survey on deep learning in medical image analysis. arXiv preprint; arXiv:1702.05747 [cs.CV] (19 Feb 2017).
- Lu, Jie, et al. "Recommender system application developments: a survey." *Decision Support Systems* 74 (2015): 12-32.
- L. Marconi, C. Melchiorri, M. Beetz, D. Pangercic, R. Siegwart, S. Leutenegger, R. Carloni, S. Stramigioli, H. Bruyninckx, Patrick Doherty, Alexander Kleiner, V. Lippiello, A. Finzi, B. Siciliano, A. Sala and N. Tomatis. 2012. The SHERPA project: Smart collaboration between humans and ground-aerial robots for improving rescuing activities in alpine environments. Proc. of the IEEE Int. Workshop on Safety, Security and Rescue Robotics (SSRR). 2017
- Marcus, Gary. Innateness, AlphaZero, and Artificial Intelligence. arXiv 2018. <https://arxiv.org/abs/1801.05667>
- Does AI need more innate structures? Gary Marcus vs Yann LeCun ()
- Mnih et al, Human-level control through deep reinforcement learning, nature volume 518, pages 529–533, 2015. Self-taught AI agent masters Atari arcade games
- Matej Moravčík, Martin Schmid, Neil Burch, Viliam Lisý, Dustin Morrill, Nolan Bard, Trevor Davis, Kevin Waugh, Michael Johanson, Michael Bowling, DeepStack: Expert-level artificial intelligence in heads-up no-limit poker, Science May 2017 : 508-513
- Waseem Rawat and Zenghui Wang, Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review, Neural Computation 2017
- Richardson, M., & Domingos, P. (2006). Markov logic networks. *Journal of Machine Learning Research*, 62, 107–136.
- Rumelhart, D. E., Hinton, G. E. & Williams, R. J. Learning representations by back-propagating errors. *Nature* 323, 533–536 (1986).
- S. Russel and P. Norvig. *Artificial Intelligence: A Modern Approach*, 3rd Edition, 2009.

- Silver, D., Newnham, L., Barker, D., Weller, S. & McFall, J. Concurrent reinforcement learning from customer interactions. In Proc. 30th Int. Conf. Mach. Learn. Vol. 28 924–932 (2013)
- Silver, D. et al. Mastering the game of Go with deep neural networks and tree search. Nature. Vol 529. Jan 2016. <https://www.nature.com/articles/nature16961>
- Silver, D. et al. Mastering the game of Go without human knowledge. Nature. Vol 550. Oct 2017. <https://www.nature.com/articles/nature24270>
- Silver, D., et al. Mastering Chess and Shogi by Self-Play with a General Reinforcement Learning Algorithm <https://arxiv.org/pdf/1712.01815.pdf>
- P Simoens, M Dragone, A Saffiotti. The Internet of Robotic Things: A review of concept, added value and applications. International Journal of Advanced Robotic Systems 15 (1), 2018
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. & Salakhutdinov, R. Dropout: a simple way to prevent neural networks from overfitting. J. Machine Learning Res. 15, 1929–1958 (2014).
- Sutskever, I. Vinyals, O. & Le. Q. V. Sequence to sequence learning with neural networks. In Proc. Advances in Neural Information Processing Systems 27 3104–3112 (2014). This paper showed state-of-the-art machine translation results with the architecture introduced in ref. 72, with a recurrent network trained to read a sentence in one language, produce a semantic representation of its meaning, and generate a translation in another language.
- Weston, J., Bordes, A., Chopra, S. & Mikolov, T. Towards AI-complete question answering: a set of prerequisite toy tasks. <http://arxiv.org.e.bibl.liu.se/abs/1502.05698> (2015).
- Håkan Warnquist, Jonas Kvarnström and Patrick Doherty. A Modeling Framework for Troubleshooting Automotive Systems. Applied Artificial Intelligence, 30(3):257–296. 2016.
- Wing, Jeanette. Computational thinking. Commun. ACM 49, 3 (2006), 33–35.
- T Ziemke, KE Schaefer, M Endsley. Situation awareness in human-machine interactive systems. Cognitive Systems Research 46, 1-2. 2017.