

Återkopplade Neuronnät

Axel Engberg,

Kandidatavhandling i datavetenskap,

Handledare: Sepinoud Azimi,

Fakulteten för naturvetenskaper och teknik,

Åbo Akademi,

2021

Referat

...

Innehållsförteckning

Referat	2
Inledning	4
Maskininlärning	5
Artificiella Neuronnät	7
Bakåtpropagering.....	9
Djupinlärning	9
Återkopplade Neuronnät	11
Bakåtpropagering genom tiden	12
Långt korttidsminnes nätverk	12
Tillämpningar.....	13
Begränsningar	13
Källförteckning.....	13

Inledning

”Artificiell intelligens” är ett uttryck som man hör allt oftare. Det har varit en dröm både inom vetenskapen och science fiction att skapa datorer med mänsklig intelligens ända sedan de första datorerna byggdes. År 2021 så är vi en god bit på väg. Utvecklingen av artificiell intelligens har tagit fart under de senaste åren tack vare effektivare datorer och stora mängder av data, tillgängliga för analys.

Datorer kan idag bland annat känna igen vägskyltar, förstå vad man säger och komponera musik. År 2016 så besegrade Googles AlphaGo världsmästaren i Go, Lee Sedol. Go är ett kinesiskt brädspel som länge ansågs vara för kreativt för maskiner att klara av att spela på samma nivå som människor. Datorer har blivit mer kreativa och utvecklingen har skett snabbt. Men samtidigt är vi fortfarande ett par genombrott ifrån att skapa generell intelligens.

Maskininlärning och specifikt olika former av djupinlärning står bakom många av de genombrott som gjorts under de senaste åren. Djupinlärning är inspirerat av hjärnan och kan ”lära sig” abstraktioner och helheter genom att utnyttja en algoritm som kallas för bakåtpropagering.

Djupinlärning består av lager av ”neuroner” som är anslutna till varandra. Det finns ett ingångslager för indata, två eller flera dolda lager och ett responslager för utdata. Vanligt är att man tränar en djupinlärningsalgoritm att lära sig samband mellan några indata och en målvariabel. Ingångslagret tar emot indata som propageras framåt genom nätverket, ett lager i taget tills de når responslagret. Det är de dolda lagren som möjliggör lärandet av helheter och abstraktioner.

Återkopplade neuronät är en vidareutveckling av djupinlärning som kan bearbeta sekvensdata och används flitigt inom språkteknologi. Återkopplade neuronät sparar information om tidigare datapunkter i en sekvens i en ”tillståndsvektor” som sedan används när senare datapunkter behandlas.

Tillståndsvektorn fungerar alltså som en slags historik för den del av sekvensen som har behandlats.

Maskininlärning

Maskininlärning är ett delområde inom artificiell intelligens som går ut på att låta datorprogram lära sig av data, istället för att explicit programmera deras beteende. Om ett problem är tillräckligt komplicerat eller abstrakt så kan det vara svårt för en människa att programmera en lösning för hand. I sådana situationer kan maskininlärning vara lösningen.

Maskininlärning fick sitt startskott år 1955 när Arthur Samuel skrev ett datorprogram som kunde lära sig att spela dam. Programmet lärde sig strategier för att vinna genom att spela matcher mot sig själv. [1]

Om maskininlärning som ämne så skrev Samuel bland annat att "en dator kan programmeras så att den kan lära sig att spela dam bättre än personen som skrev programmet". Han jämförde också maskininlärning med att programmera för hand på följande vis: "att programmera datorer att lära sig från erfarenhet kommer så småningom att eliminera behovet för mycket av denna detaljerade programmeringsinsats." [1]

En mer exakt definition på maskininlärning av Tom Mitchell lyder: "ett datorprogram sägs lära sig av erfarenhet E givet en uppgift T och ett prestandamått P om dess prestanda på uppgiften T , mätt med P , ökar med erfarenhet E ." [2]

Maskininlärning kan delas in i övervakad inlärning, oövervakad inlärning och förstärknings-inlärning. Typen av inlärning beror på hurdana data man jobbar med. Övervakad inlärning innebär att man har data i formen av (X, y) och man försöker träna algoritmen att lära sig sambandet mellan X och y . Målet är att efter att algoritmen tränats så ska den kunna förutsäga ett givet \hat{y} som respons på

hittills osedda indata x . Övervakad inlärning är den vanligaste formen av maskininlärning. [3]

Oövervakad inlärning betyder att man har strukturerade data men man har ingen målvariabel y . Istället använder man maskininlärning för att upptäcka samband mellan olika variabler i ens dataset. Klusteranalys är ett exempel på oövervakad inlärning.

I förstärkningsinlärning så lär sig maskininkärningsalgoritmen genom att prova sig fram i en virtuell miljö med vissa regler. Reglerna är definierade på förhand och det är också målet med inlärningen. När algoritmen kommer närmare målet så får den en "belöning" och inlärnings-processen går ut på att maximera belöningen.

Under de senaste åren så har användningen av maskininlärning ökat markant. Det finns två huvudsakliga orsaker till det här. För det första så har mängden tillgängliga data ökat. Våldiga mängder data genereras av människor som spenderar tid på sina smarttelefoner och på internet. Dessa data är också väldigt detaljerade och personliga. [3]

Det kan vara frågan om olika former av webbaktiviteter, platsdata, användningsdata från appar och så vidare. Det är en utmaning att bearbeta dessa data på grund av att det är frågan om sådana enorma mängder. Maskininlärning gynnas av större dataset och är ofta ett lämpligt verktyg för att utnyttja alla dessa data.

För det andra så har datorer blivit betydligt mer kraftfulla. Det krävs effektiva datorer för att lagra och bearbeta alla data som genereras hela tiden. Effektivare datorer har också möjliggjort användningen av mer beräkningsmässigt krävande maskininlärningsalgoritmer. [3]

Kombinationen av stora mängder personliga data, effektiva datorer och maskininlärning möjliggör utvecklandet av personliga tjänster på stor skala. Till

exempel inom sjukvården utvecklas det tjänster som utnyttjar olika personliga hälsodata som exempel sjukhistorik, dna, längd, vikt och så vidare för att hjälpa med diagnostisering av sjukdomar, ge dig en översikt över ditt hälsotillstånd och komma med personliga rekommendationer för att förbättra din hälsa. [4]

Artificiella Neuronnät

Artificiella neuronnät, eller neurala nätverk, är en maskininlärningsalgoritm. Neuronnät är inspirerade av hjärnan, som har flera fördelar om man jämför med processorn hos en dator. Hjärnans struktur är parallell, den kan göra flera saker samtidigt, medan en dator utför alla beräkningar en i taget. En annan sak som människor kan göra relativt enkelt är att förstå helheter och abstraktioner. Det är nästan omöjligt att programmera en dator att göra samma sak. [2] [5]

Den första varianten av artificiella neuronnät, perceptronen, uppfanns år 1957 av den amerikanska psykologen Frank Rosenblatt [6]. Den här modellen har senare vidareutvecklats till mer komplicerade varianter av artificiella neuronnät.

Neuronnät är dock endast inspirerade av hjärnan, det är inte frågan om att vi skulle kunna simulera en hjärna i en dator genom artificiella neuronnät. Vi vet inte hur biologiska hjärnor fungerar, därför kan vi inte simulera dem heller. [2] [5]

En enkel form av neuronnät består av tre "lager" av neuroner: ett ingångslager, ett dolt lager och ett responslager. Varje neuron i ett lager är ansluten till alla neuroner i det följande lagret. Varje anslutning har en vikt och det är genom att justera de här vikterna som ett neuronnät kan "lära sig". Det finns mer avancerade varianter av neuronnät som har flera dolda lager och dessa kallas för "djupinlärning". [2] [5]

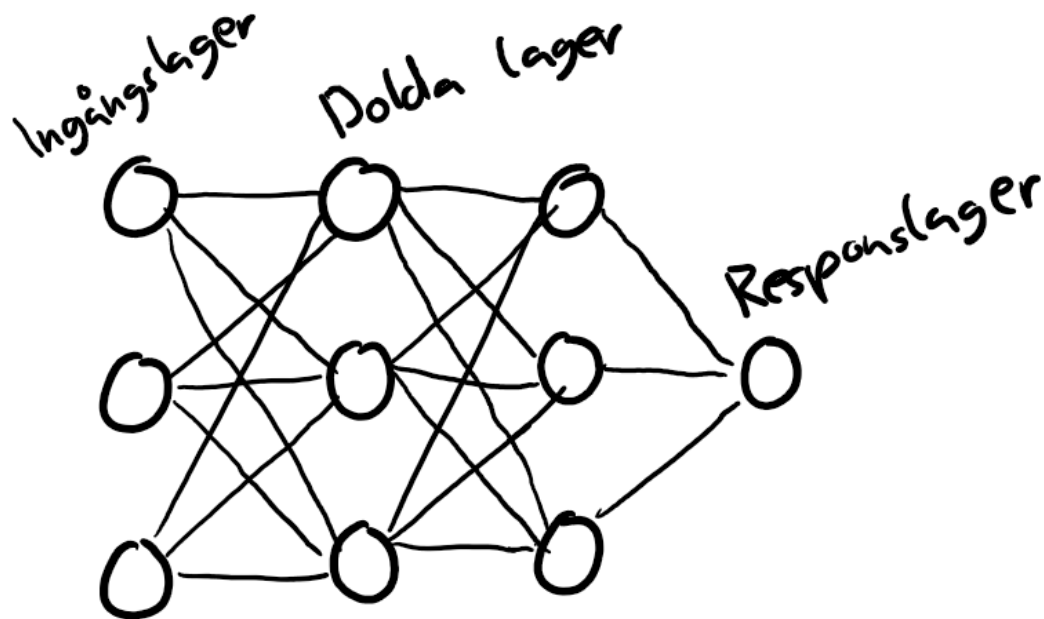


Illustration av ett neuronät med två dolda lager (placeholder).

Vanliga neuronät lär sig huvudsakligen av strukturerade data, det vill säga data som går att organisera i tabeller. I sådana tabeller brukar varje kolumn vara en egenskap hos det som undersöks och varje rad ett exempel. Exempelvis om vår tabell består av lägenheter till salu, så skulle vi kunna ha kolumner som beskriver antalet kvadratmeter, antalet rum och priset på lägenheter. Varje rad skulle vara en lägenhet med en unik adress. Ett neuronät skulle sedan kunna tränas att förutspå priset på en lägenhet beroende på antalet kvadratmeter och rum.

Antalet neuroner i ingångslagret är alltid lika många som antalet kolumner i tabellen som neuronätet ska läsa. Därefter kommer en eller flera dolda lager för vilka man själv bestämmer antalet neuroner. Slutligen, för responslagret så varierar antal neuroner beroende på formatet som resultatet kommer i. Om vi förutspår priser på lägenheter skulle det vara ett neuron, som ger ett tal som resultat.

Ett neuronnät är en så kallad universell approximerare (Eng. universal approximator). Det betyder att alla matematiska funktioner kan uppskattas med artificiella neuronnät. Man kan alltså i teorin lära ett neuronnät vad som helst om det kan uttryckas som en matematisk funktion. I praktiken är neuronnät begränsade av mängden tillgängliga data och av datorers prestanda. [2] [5]

Bakåtpropagering

Det finns flera sätt att träna ett artificiellt neuronnät, men vanligast är att man använder bakåtpropagering. Det är en algoritm som utnyttjar gradientnedstigning för att uppdatera vikterna i neuronnät.

Djupinlärning

Djupinlärning är en mer avancerad form av artificiella neuronnät. Det är huvudsakligen djupinlärning och olika vidareutvecklingar av djupinlärning som stått för många av de framsteg som gjorts under de senaste åren. Den enklaste formen av djupinlärning är ett artificiellt neuronnät med flera dolda lager. [1] [4]

Idén bakom djupinlärning är att flera dolda lager ska möjliggöra att datorn kan lära sig mer komplicerade abstraktioner och på det här sättet klara av att hantera komplicerade helheter. Djupinlärning lär sig alltså en abstrakt representation av data och algoritmen kan sedan använda den här interna representationen för att göra förutsägelser och prognoser. [7]

Ett område där djupinlärning används mycket är bildanalys. Om man till exempel vill känna igen bilar med hjälp av djupinlärning så kan man tänka sig att algoritmen fungerar på följande vis. Ingångslagret bearbetar pixeldata från bilderna. Det första dolda lagret lär sig enkla geometriska figurer och mönster. Nästa dolda lager använder den interna representationen från det förra dolda lagret för att känna igen vissa delar av bilen, som hjulen, lyktorna, fönstren och bilens form. Slutligen kan algoritmen avgöra om det är frågan om en bil eller inte. Har den fyra hjul, fram- och baklyktor, fönster på rätt ställe och rätt form? Då är det en bil.

Det viktiga är att djupinlärning kan lära sig de abstraktioner som behövs. I exemplet ovan så fanns det bara två dolda lager, men oftast så använder man ännu fler lager. De tidigare lagren lär sig enkla byggstenar som de senare lagren kan använda för att representera abstrakta helheter.

Andra maskininlärningsalgoritmer är inte lika bra på att lära sig interna representationer av data. Innan djupinlärning blev populärt så måste man använda mycket tid på att för hand manipulera data så att det lämpade sig för maskininlärning. För djupinlärning är det här behovet inte lika stort, eftersom algoritmen själv kan avgöra vilka samband är viktiga och hurdana abstraktioner som behövs. [7]

Djupinlärning har gynnats speciellt mycket av de stora mängderna data som idag finns tillgängliga. För maskininlärningsalgoritmer som inte kan lära sig abstraktioner utan kräver att man för hand bygger system för särdragsextraktion så innebär större datamängder också mer jobb. För djupinlärning är det här inte ett problem.

Återkopplade Neuronnät

Återkopplade neuronnät (Eng. recurrent neural networks) är en vidareutveckling av djupinlärning som kan bearbeta sekvensdata. Vanliga neuronnät antar att datapunkter är oberoende från varandra, vilket är otillräckligt för sekvensdata. Till exempel om man ska behandla text, då räcker det inte att behandla orden skiljt för sig eftersom ordningen på orden också spelar roll. [8]

I återkopplade neuronnät behandlas datasekvenser så att information om tidigare datapunkter skickas vidare i nätverket och används för att bearbeta senare datapunkter. På det sättet kan till exempel en mening behandlas som en mening, istället för bara en samling ord. [8]

När man talar om återkopplade neuronnät så handlar det oftast övervakad inlärning. I övervakad inlärning så man indata och en målvariabel och för återkopplade neuronnät så är det frågan om sekvenser. Dock behöver inte båda vara sekvenser, det kan också vara så att man har en indata sekvens och en enskild målvariabel eller en enskild indatavariabel och en målsekvens. En indata sekvens kan betecknas $(x^{<1>}, x^{<2>}, \dots, x^{<T>})$ och en målsekvens kan betecknas $(y^{<1>}, y^{<2>}, \dots, y^{<T>})$. [8]

En "tillståndsvektor" används för att spara information om datapunkter i sekvensen som har behandlats tidigare. Det är tillståndsvektorn som skiljer ett vanligt neuronnät från ett återkopplat neuronnät. Tillståndsvektorn kan betecknas $(a^{<1>}, a^{<2>}, \dots, a^{<T>})$. Det här är den enklaste formen av ett återkopplat neuronnät och det har vissa begränsningar. En av begränsningarna är att den här arkitekturen är svår att träna med bakåtpropagering eftersom gradienterna ofta försvinner eller exploderar.

Det finns mer avancerade arkitekturer av återkopplade neuronnät som exempelvis långt korttidsminnes nätverk (Eng. "Long short-term memory" ofta förkortat till "LSTM") som klarar av bakåtpropageringen bättre.




Illustration av ett återkopplat neuronnät (placeholder).

Bakåtpropagering genom tiden

...

Långt korttidsminnes nätverk

...

Tillämpningar

...

Begränsningar

...

Källförteckning

- [1] A. L. Samuel, "Some Studies in Machine Learning Using the Game of Checkers," *IBM Journal of research and development*, vol. 3, nr 3, pp. 210-229, 1959.
- [2] T. M. Mitchell, *Machine Learning*, McGraw-Hill Science/Engineering/Math, 1997.
- [3] M. I. Jordan och T. M. Mitchell, "Machine learning: Trends, perspectives, and prospects," *Science*, vol. 349, nr 6245, pp. 255-260, 2015.
- [4] S. Dash, S. K. Shakyawar, M. Sharma och S. Kaushik, "Big data in healthcare: management, analysis and future prospects," *Journal of Big Data*, vol. 6, nr 54, 2019.
- [5] S. Haykin, *Neural Networks: A Comprehensive Foundation (2nd Edition)*, Pearson Education Inc, 1999.
- [6] F. Rosenblatt, "The perceptron: a probabilistic model for information storage an optimization," *Psychological review*, vol. 65, nr 6, pp. 386-408, 1958.

- [7] Y. LeCun, Y. Bengio och G. Hinton, "Deep learning," *Nature*, vol. 521, nr 7553, pp. 436-444, 2015.
- [8] Z. C. Lipton, J. Berkowitz och C. Elkan, "A Critical Review of Recurrent Neural Networks for Sequence Learning," arXiv: 1506.00019, 2015.