

Maskininlärning - mer än bara science fiction!

Oliver Bäckström

19 juni 2025

Det finns förmodligen inte en enda människa på jorden som inte har sett dem eller hört talas om dem. Terminator, R2-D2 och Wall-E är ett axplock av de många robotar som finns inom populärkulturen. De kan prata och socialisera och utför till och med vissa uppgifter bättre än oss människor. De kan agera självständigt även i nya situationer. Vi kanske inte riktigt kommit dit idag, men en gren inom datavetenskapen kämpar febrilt för att vi ska komma så nära som möjligt. Det kallas för maskininlärning och innebär precis vad namnet ger uttryck för. Att låta en dator lära sig av sig själv.

Problemet med att låta datorer komma till insikter själva är det faktum att de är extremt bokstavliga. Om man ger en dator en viss instruktion gör den precis vad du säger till den att göra. Den gör ingen självständig bedömning för att kontrollera att det du ber om är rimligt. Om du har rätt administratörsrättigheter kommer den glatt att hjälpa dig ta bort alla de nödvändiga systemfilerna - och förmodligen känna sig stolt som en hund som precis lytt kommandot att sätta sig ner. För att åstadkomma intelligent inlärning måste vi använda denna tendens till att vara bokstavlig på ett kreativt sätt.


Maskininlärning innebär därför kort och gott att ge datorn exempel på vad som är korrekt beteende. Ger man tillräckligt många exempel lyckas datorn hitta relevanta samband som gör så att datorn kan bete sig intelligent även i situationer som inte är lika bekanta för datorn. Detta kan liknas vid ett barn som lär sig att ta sina första steg. Det finns en kraftig drift hos barn att vilja utforska världen, vilket driver dem till att stå upp och gå. När de ramlar fås omedelbar feedback som driver barnet till att göra annorlunda nästa gång. Barnet provar igen och igen tills det uppnådda målet har nåtts.

En relevant detalj är att barnet inte explicit behöver hålla reda på några detaljer kring vilka muskler som ska aktiveras när. Hjärnan sköter detta. Det som ytterst styr är viljan att gå. Detaljerna kring hur detta uppnås är mindre viktiga och löses av hjärnans "maskininlärningsalgoritm".

Maskininlärning i ett sågverk

Mitt arbete har handlat om att tillämpa maskininlärning inom en industriell kontext. Mer specifikt i ett sågverk. In kommer stockar, ut kommer färdigskurna och paketerade plankor. Arbetet har fokuserat på en specifik maskin - en så kallad unsrambler. Dess syfte är att separera plankor som ligger huller om

buller, så att plankorna plockas ut en och en. Maskinen består av rullband som plockar upp plankor från ett dike. Tanken är att detta ska göras så effektivt som möjligt och utan att plankorna hamnar ovanpå varandra. Eftersom vi inte lever i en ideal värld så är detta inte alltid fallet. Målet med effektiviseringen är att behålla eller öka effektiviteten samtidigt som andelen dubbla plankor hålls konstant, eller till och med sänks. Processen visas grafiskt i Figur 1.



Figur 1: Unscramblerprocessen sedd från sidan. Plankor inkommer huller om buller från höger och plockar upp av Unscrambler 1 och 2 från respektive dike. Målet är att Unscrambler 2 ska plocka upp plankor från Dike 2 så effektivt som möjligt, och utan att dessa hamnar ovanpå varandra.

Problemet vid arbetets start var att det inte fanns särskilt mycket kunskap om maskinen. I detta sågverk kör man många olika storlekar på virket. Maskinen betar sig annorlunda beroende på virkesstorlek och virkeskvalité. Det är önskvärt att en eventuell modell automatiskt ska kunna ställa in maskinen så att den betar sig optimalt för varje enskild virkestyp och virkesstorlek. I denna process går det att ändra önskvärd hastighet på bandet, nivå i diket som bandet plockar upp brädor ifrån samt vilken greppmån bandet ska ha när det plockar upp plankor från diket.

För att en modell ska kunna göra något användbart är det nödvändigt med data som väl representerar processen. Om man vill lära sig spela trumpet tar man in en trumpetlärare som visar en rätt väg. Insamlandet av data blir som modellens lärare. Och precis som vilket läromedel som helst har kvalitén på läromedlet stor betydelse. Om datan inte samlas in med omsorg, filtreras och bearbetas på smarta sätt kan vi inte förvänta oss att en modell skulle kunna lära sig åstadkomma något med hjälp av den. Genom datan kan datorn veta vilka tillvägagångssätt som är rimliga.

Målet är att modellen ska kunna förutspå optimala maskininställningar. Men eftersom det på sågverket inte finns kunskap om vilka inställningar som är optimala kommer datan spegla denna okunskap. Hur kan man då, med bristfällig data, skapa en modell som lyckas förutspå optimala maskinparametrar? Lösningen blir att med hjälp av datan konstruera en modell som förutspår utfallet givet

vissa inställningar. In i modellen skjutsar vi in virkesdimensioner och maskininställningar. För dessa inställningar producerar därefter modellen en prediktion på vad utfallet troligtvis kommer att vara. Till skillnad från den verkliga processen är modellen inte kostsam att köra vilket innebär att det går att testa hundratals kombinationer av parametrar och sedan välja ut de som resulterade i optimala utfall.

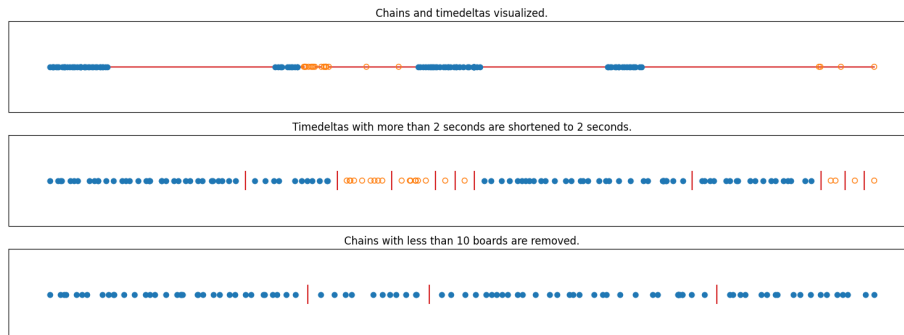
För att förtydliga innebörden av detta tas ett hypotetiskt exempel. Föreställ er att ni är ingenjörer på NASA med uppgift att konstruera styrningen av rymdsonden som befinner sig på planeten Mars. Problemet med att kontrollera denna sond från Jorden är det faktum att tvåvägskommunikation med sonden totalt tar omkring 25 minuter. Om vi skulle framföra denna sond som vi framför bilar skulle vi behöva göra en liten manövrering, vänta 25 minuter på att få resultatet av den manövreringen och sedan göra nästa manövrering. Det innebär en väldig massa väntande. Men om man konstruerar en modell av sonden och skannar av miljön som sonden befinner sig i, skulle man kunna styra sonden i modellen och förutspå hur sonden skulle bete sig i den verkliga miljön. Om modellen är tillräckligt bra skulle det gå att utföra komplexa operationer på rad i modellen och sedan skicka dessa till sonden. Då har man plötsligt kortat ned ledtiden avsevärt. På samma sätt ger vår modell oss möjligheten att inom loppet av några sekunder utvärdera hundratals olika maskinparametrar och välja de som är mest optimala.

Utfall

Maskinen som har studerats befinner sig i en begränsande kontext. Den tvingas ofta stanna på grund av att nästkommande maskin i förloppet fylls upp. Inbyggt i sättet som man idag mäter effektivitet på bestraffas maskinen något vid varje stopp, trots att maskinen inte alltid kan rå för dessa stopp. Därför märkes ingen förbättring alls när maskinen använde sig av modellen. De som arbetade på sågverket verkade däremot tycka att maskinen plockade bättre. Det verkade som att när maskinen arbetade effektivare, ledde det till att nästkommande maskin blev fylld fortare, vilket ledde till fler maskinstopp vilket i sin tur drog ner prestandamätningen. För att se maskinens prestanda i kontinuerlig drift behövdes ett nytt sätt att filtrera datan på.

Hur kan man då ta bort dynamiska effekter för effektivitetsmätningen? Lösningen blev ett filtreringsschema som tittar på alla plankor i ett givet paket som passerar maskinen. Alla intervall mellan registrerade plankor som överstiger 2 sekunder kortas ner till 2 sekunder. När maskinen kör i kontinuerlig drift ska det normalt inte vara mer tid mellan plankor än såhär. Den andra filtreringen tar bort kedjor med plankor som är väldigt små till antalet. Är de inte tillräckligt många hinner maskinen inte komma upp i varv. Dessa två sätt att filtrera datan tar bort många av de dynamiska effekterna som modellen inte tar hänsyn till. Med detta sätt att bearbeta datan på märktes en 5-10-procentig effektivitetsförbättring när maskinen väl plockar. Andelen dubbla bräddor fördubblades dock. Grafiskt visas denna filtrering i Figur 2.

Den relevanta slutsatsen som visats genom arbetet är att maskinen kan pre-



Figur 2: Filtrering av paket i syfte att sätta ett mer rättvist och oberoende effektivitetsvärde på paketet. Alla x-axlar anger tid. Grafen längst upp ger en bild av hur alla plankor i ett paket passerat sensorn ofiltrerat. Den mellersta grafen visar hur paketet förändras då mellanrum längre än 2 sekunder kortas ner till 2 sekunder. Den sista grafen visar hur paketet förändras då plankkedjor med färre än 10 plankor tas bort. Observera att alla tre grafers x-axlar har olika tidsskalor då hålrums och kedjor med få plankor tas bort.

stera bättre om man är villig att låta operatörerna utföra mer manuellt arbete. Maskinen är gammal och har inte förändrats särskilt mycket under sin livslängd. Det är ingen optimal miljö för maskininlärning att frodas i. Trots detta gick det att få till ett bra resultat med bara några få månaders datainsamling och programutveckling. I teorin kommer modellen dessutom bara att bli bättre i takt med att mer data samlas in. På så sätt är det ett arbete som kontinuerligt kan ge mervärde.

Även om det inte hade gått att visa på en förbättring av effektiviteten har arbetet resulterat i många fördelar. På sågverket finns nu avsevärt mycket bättre förståelse för processen. Processen finns också konkret beskriven i detalj i den rigorösa datainsamlingen. Under utvecklingens gång har mycket statistik tagits fram som är användbar inom andra områden också. Även om maskininlärningen har varit arbetets fokus har många bifördelar dykt upp på utvecklingsvägen.

Sammanfattning

Sammanfattningsvis är maskininlärning inte längre science fiction - det används aktivt här och nu. Arbetet har visat att maskininlärning i allra högsta grad kan förbättra befintliga industriella maskiner. I det aktuella arbetet gick det att se en effektivitetsförbättring på 5-10% när dynamiska effekter filtrerats bort. I en industriell kontext är denna procentsats väldigt hög, speciellt med tanke på att inga mekaniska förändringar av maskinen gjordes. Det råder ingen tvekan om att maskininlärning är något vi alla kommer att se mer av i framtiden.