

Neurale netværk som beslutningsstøtteværktøj

En introduktion

Det er ikke nogen overraskelse, at der i de senere år er sket en væsentlig udvikling i teknologi og anvendelse af neurale netværk. Det er dog ikke altid let at få et godt overblik over, hvordan teknologien virker og hvilke muligheder den tilbyder. Dette artikkel vil forsøge at give et grundlæggende overblik over, hvordan neurale netværk fungerer, hvilke anvendelser der findes og hvordan teknologien kan bruges til at understøtte beslutningsprocessen.

Af Knud Erik Rasmussen

Resumé

Artiklen giver en grundlæggende, ikke-teknisk introduktion til kunstige neurale netværk. Et eksempel på anvendelse af neurale netværk i forbindelse med going concern-problemstillingen beskrives. Desuden beskrives et igangværende dansk projekt vedrørende anvendelse af neurale netværk i forbindelse med ligning af erhvervsdrivendes selvangivelser, samt et eksempel på anvendelse af neurale netværk til vurdering af virksomheder.

Indledning

Kunstige neurale netværk udspringer af forskningen i kunstig intelligens-teknikker. Kunstige neurale netværk har fundet anvendelse på en bred vifte af problemstillinger, ikke kun inden for det tekniske / naturvidenskabelige område (f.eks. »robotsyn« til automatisk styring af en bil, og genkendelse af fjendtlige fartøjer til brug inden for militæret), men også på områder som transformering af skrevet tekst til tale, og omvendt. I industrien er bl.a. set anvendelser til kvalitetskontrol og til produktionsstyring.

På det erhvervsøkonomiske område er der i de senere år set anvendelser inden for så forskellige områder som vurdering af værdipapirer, prognosticering af kortperiodiske udsving i aktiekurser, forudsigelse af

Neurale netværk som beslutningsstøtteværktøj

En introduktion

Det er ikke nogen overraskelse, at der i de senere år er sket en væsentlig udvikling i teknologi og anvendelse af neurale netværk. Det er dog ikke altid let at få et godt overblik over, hvordan teknologien virker og hvilke muligheder den tilbyder. Dette artikkel vil forsøge at give et grundlæggende overblik over, hvordan neurale netværk fungerer, hvilke anvendelser der findes og hvordan teknologien kan bruges til at understøtte beslutningsprocessen.

Af Knud Erik Rasmussen

Resumé

Artiklen giver en grundlæggende, ikke-teknisk introduktion til kunstige neurale netværk. Et eksempel på anvendelse af neurale netværk i forbindelse med going concern-problemstillingen beskrives. Desuden beskrives et igangværende dansk projekt vedrørende anvendelse af neurale netværk i forbindelse med ligning af erhvervsdrivendes selvangivelser, samt et eksempel på anvendelse af neurale netværk til vurdering af virksomheder.

Indledning

Kunstige neurale netværk udspringer af forskningen i kunstig intelligens-teknikker. Kunstige neurale netværk har fundet anvendelse på en bred vifte af problemstillinger, ikke kun inden for det tekniske / naturvidenskabelige område (f.eks. »robotsyn« til automatisk styring af en bil, og genkendelse af fjendtlige fartøjer til brug inden for militæret), men også på områder som transformering af skrevet tekst til tale, og omvendt. I industrien er bl.a. set anvendelser til kvalitetskontrol og til produktionsstyring.

På det erhvervsøkonomiske område er der i de senere år set anvendelser inden for så forskellige områder som vurdering af værdipapirer, prognosticering af kortperiodiske udsving i aktiekurser, forudsigelse af

sandsynlige konkurser, og som en alternativ angrebsvinkel på optimeringsproblemstillinger. I artiklen gennemgås nogle eksempler på hvorledes man har grebet disse problemstillinger an. Herigenom argumenteres også for, at denne teknologi sandsynligvis har nogle uudnyttede potentiader inden for det erhvervsøkonomiske område.

Det »nye« i anvendelsen af kunstige neurale netværk på bl.a. det erhvervsøkonomiske område er begrebet om »lærende« systemer, d.v.s. systemer som er i stand til ud fra et empirisk erfaringssmateriale at lære nogle generelle sammenhænge (eller lidt flot: »teorier«) på et snævert afgrænset område, og ud fra denne »visdom« forudsige korrekte udviklinger og/eller foretage korrekte klassifikationer.

Af dette følger, at anvendelse af neurale netværk primært vil være interessant på områder, hvor man mangler gode teorier og/eller modeller, eller hvor domænet er helt eller delvist udforsket.

En teoris kvalitet kan, foruden forudsækskraften, også vurderes på dens forklaringskraft. Her har kunstige neurale netværk indtil videre en svaghed, idet den »visdom«, som et sådant netværk tilegner sig ved træning, ikke er umiddelbart tilgængelig i en form, som kan omsættes til domænefaglige begreber. Den visdom, som netværket besidder, er i en vis forstand en »black box«, bestående af en matrice af numeriske værdier, som ikke direkte kan relateres til begreber fra træningsmaterialet.

Det fremhæves ofte, at kunstige neurale netværk i højere grad end f.eks. traditionelle statistiske teknikker er i stand til korrekt at afdække eller »lære« komplek-

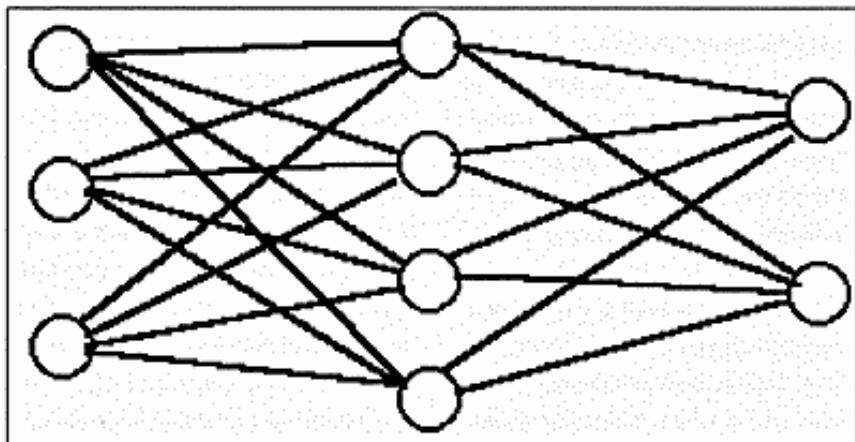
se mønstre i et givet datamateriale (Dutta & Shekhar, 1989; Hansen & Messier, 1991). En del af forklaringen er, at anvendelse af kunstige neurale netværk ikke forudsætter f.eks. antagelser om bestemte fordelinger i datamaterialet, eller a priori formulering af funktionelle sammenhænge på matematisk form. Med andre ord er der færre kompleksitetsbegrensninger, og hermed også mulighed for »læring« af særlig komplikerede sammenhænge i et givet erfaringssmateriale.

Hvordan fungerer kunstige neurale netværk?

Kunstige neurale netværk er i principippet bygget op med udgangspunkt i (eller snare inspiration fra) den menneskelige hjernes biologiske funktionsmåde. De er i stand til at »lære« og genkende selv ret komplikerede mønstre i et givet datamateriale.

Til illustration af et kunstigt neutralt netværks funktionsmåde skal her gives en noget forenklet, principiel beskrivelse af en af de mest udbredte netværkstyper, det såkaldte Back Propagation Network (BPN), se side 59.

Et kunstigt neutralt netværk kan betragtes som bestående af et antal simple processorer (»neuroner«), som er forbundet til hinanden ved hjælp af ledninger (»forbindelser«, »konnektorer«). Processorerne er organiseret i lag, således at en givet processor i et givet lag har forbindelser til alle processorer i laget »oven over« og i laget »neden under«.



Inputlag skjult lag Outputlag

Processorerne består hver for sig af 3 elementer:

- 1) en aktiveringsenhed, som summerer de indkommende signaler fra laget neden under til én værdi
- 2) en transforméringsfunktion, ved hjælp af hvilken det afgøres hvilket signal der skal sendes videre. Denne funktion kan have forskelligt udseende, alt afhængigt af netværkets konkrete anvendelse.
- 3) en outputenhed (har ikke noget at gøre med outputlaget), som sørger for at sende signalet videre til processorerne i laget »oven over».

Ledningerne forbindelserne har udover at være transportveje for signalerne også den vigtige egenskab, at de bærer numeriske vægte. Det signal, som passerer gennem en given forbindelse, bliver multipliceret med den vægt, som er knyttet til denne forbindelse. D.v.s. at summeringen i den modtagende processor i virkeligheden er en vægtet summing af de signaler, som

ankommer til denne processor. Man taler om en *exitatorisk* forbindelse, hvis vægten er positiv, og en *inhibitorisk* forbindelse, hvis vægten er negativ. Disse vægtes værdier ligger ikke fast, men ændres under træningen, og det er bl.a. disse vægte, som på en ret abstrakt form udgør den »viden«, som netværket tillegner sig under opklæring.

Inputlag og outputlag

I forbindelse med såvel opklæring som test og brug af netværket har input- og outputlaget en særlig funktion. I inputlaget »fodres« det opklært netværk med oplysninger om den foreliggende beslutningssituation. I outputlaget presenteres beslutningsforslaget/ konklusionen.

I mange tilfælde har konklusionen karakter af en klassificering, hvorfor man i outputlaget vil anvende én neuron pr. muligt udfald. Værdierne på de enkelte outputneuroner kan så tolkes som den relative styrke i konklusionen. Ved en klar konklusion vil én neuron have en høj værdi, og de resterende lave værdier. Ved en me-

re »usikker» konklusion vil evt. flere neuroner have samme høje værdi.

Multiple numeriske output kan også tolkes som et sammenhængende datasæt, f.eks. beskrivelse af en sandsynlig aktiekursudvikling over en periode.

Endelig kan man forestille sig anvendelser, som ikke omhandler numeriske in- og output, men istedet symbolske in/output, f.eks. transformering af tekst til tale og billedebehandling. I så fald sker der internt en »oversættelse« til/fra numeriske størrelser før input og efter output.

Træning af netværket

I modsætning til traditionelle computerprogrammer skal et kunstigt neutralt netværk ikke programmeres, men *trænes* med et hertil egnet værktøj. Dette sker ved at netværket gentagne gange præsenteres for et datasæt, bestående af eksempler på problemstillinger og deres rigtige løsning/konklusion. For hvert eksempel beregner netværket sit eget forslag til outputværdi(er), og sammenligner dette forslag med den rigtige løsning/konklusion.

Beregningen foretages ved at beskrivelsesdata puttes på processorerne i inputlaget som signaler. Herefter sendes disse signaler videre til næste lag i netværket, og udsættes her for den vægtede summering, transformation m.m. (som beskrevet ovenfor) for til sidst at ende som signaler i outputlaget. Disse værdier kan nu sammenlignes med de rigtige værdier fra træningssættet.

I de første gennemløb af træningssættet vil der typisk være tale om store afvigelser mellem de beregnede værdier og den rigtige løsning, eftersom vægtene i netværket initialt sættes til »tilfældige« værdier.

Derfor vil systemet ved hjælp af en *indlæringsalgoritme* øge at korrigere for disse afvigelser ved en marginal justering af vægtene i den »rigtige« retning. Denne korrigering foregår ved hjælp af en slags »baglæns« beregning af afvigelserne ved de enkelte processorer. Efter et antal gennemløb af datamaterialet vil netværkets vægte have værdier, som gør det i stand til at beregne korrekte løsningsværdier for størstedelen af materialet, f.eks. 80 eller 95 %.

Om denne situation opnås er dog afhængigt af flere forhold. Designet af netværket kan være afgørende for, om det er i stand til at »lære« noget. Det kan være, at antallet af input- og outputneuroner ikke er passende til at beskrive alle relevante aspekter af problemstillingen. Også størrelsen af det »skjulte« lag er en vigtig designparameter. Populært betegnes disse skjulte lag som netværkets »hjerne«, d.v.s. jo større skjulte lag, jo mere komplekse mønstre kan netværket håndtere. Man er typisk henvist til at eksperimentere med forskellige design for at opnå det optimale.

Successen afhænger også af datamaterialets beskaffenhed. Det kan f.eks. være, at der slet ikke er noget mønster i datamaterialet, som netværket kan lære, eller at datamaterialet indeholder atypiske eksempler, som er svære at passe ind i et generelt mønster. Her giver udviklingsværktøjerne gode muligheder for at udpege de »svære« eksempler, som så kan gøres til genstand for nærmere analyse.

Et færdigtrænet netværk skal naturligvis *testes* på andre data m.h.p. at afgøre generaliserbarheden af det indlærte. I denne forbindelse har man generelt gjort den sagtagelse, at selv netværk, som kun udviser »moderat« gode træningsresultater

(f.eks. 80 %), har gode generaliserings-egenskaber, idet test på alternative data-sæt udviser samme eller højere »opklarings-procent«.

Forudsigelse af konkurser med neurale netværk

Problemstillingen er i dette projekt revisors »going-concern«-rapport (Hansen & Messier, 1991). En almindelig forudsætning i revisionsarbejdet er, at klientens virksomhed antages fortsat at eksistere, og klienten bliver derfor behandlet som sådan. Hvis revisor har en formodning om, at dette ikke vil være tilfældet, må revisionsrapporten reflektere dette. Det turde være indlysende, at en forkert vurdering af dette forhold har alvorlige konsekvenser såvel for revisionsfirmaet som for klienten.

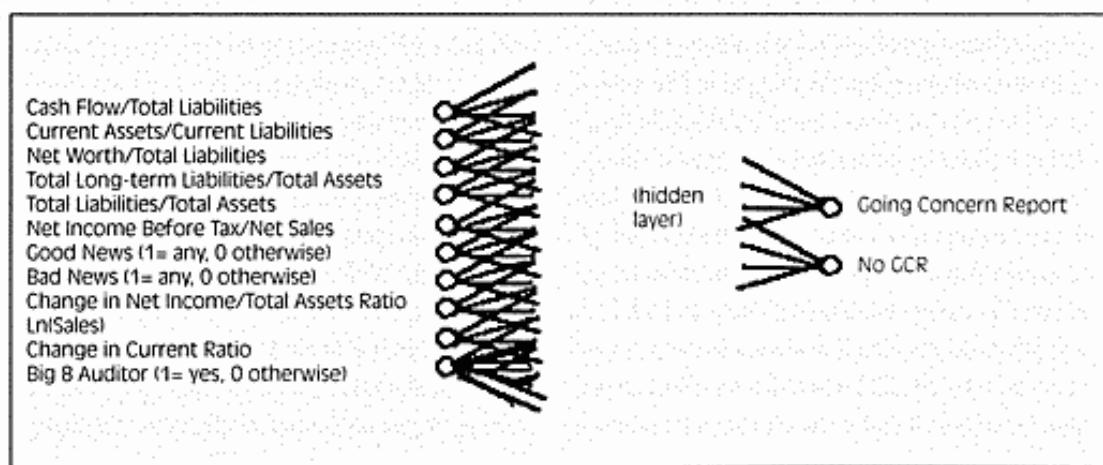
I projektet undersøgtes det, hvorvidt forskellige teknikker (neurale netværk, induktionsmetoden (generering af beslutningsregler ud fra et erfaringssmateriale) og logisk regression (en statistisk teknik), er i stand til at støtte revisors beslutning om udstedelse af en sådan påtegning. Eller med andre ord: Hvor godt kan disse teknikker hver for sig forudsige en virksom-

heds konkurs.

Problemstillingen er tidligere belyst ved hjælp af statistiske metoder og induktive, regelgenererende metoder, hvilket giver nogle sammenligningsmuligheder. Endvidere repræsenterer denne problemstilling et komplekst sæt af input (oplysninger om virksomheden m.m.), som skal forbindes med et output (beslutningen), og således formuleret vurderes neurale netværk at passe godt til denne problemstilling.

Datamaterialet var hentet fra et tidligere studie af denne problemstilling og afgrænset til fremstillingsvirksomheder, som udviste finanzielle problemer, og som henholdsvis fik eller ikke fik en sådan påtegning.

Sammenligningerne blev foretaget med logisk regression (LOGIT-proceduren i SAS-statistikpakken) og den regelinduktionsalgoritme, som er tilgængelig ved hjælp af Expert Ease. Oplæringsmaterialet bestod af 2 sæt, hver med 40 virksomheder af hver gruppe. Der var tale om et back-propagation netværk, med ét skjult lag. En model af netværket ser ud som følger (Hansen & Messier, 1991, s.140):



Resultatet af eksperimentet var som følger (Hansen & Messier, 1991, s.140):

Korrekte forudsigelser i testudvalg, i %			
	Expert Ease	LOGIT	Netværk
Udvalg 1	85,0	82,5	87,5
Udvalg 2	87,5	90,0	90,0
Gennemsnit	86,3	86,3	88,8

Med andre ord ses det, at i denne forsøgsopstilling kan et neutralt netværk levere præstationer, som er fuldt ud på højde med mere traditionelle teknikker.

Anvendelse af neurale netværk i forbindelse med ligning af selvangivelser

Projektet (udført af NEuroTech og Kommunedata) vedrører anvendelse af neurale netværk til sorterings eller prioritering af erhvervsdrivendes selvangivelser, med henblik på at udvikle et værktøj til hurtigere og mere sikker identificering af selvangivelser med fejl og/eller uregelmæssigheder, som et alternativ til en statistisk udvælgelsesmetode, og til aflastning af forvaltningens eksperter på området.

Pilotprojektet bestod i en forsøgsvis opføring af netværk baseret på udvalg fra et datamateriale bestående af ca. 17.500 selvangivelser fra 3 kommuner. Ud af samtlige felter på disse selvangivelser valgtes i alt 113 felter som inputparametre. Outputtet var »nettoprovenu«, forstået som forskellen mellem provenuet før ligning (d.v.s. hvis man accepterer de selvangivne tal som rigtige) og efter detaljeret ligning (d.v.s. en egentlig tilbundsgående behandling). Nogle resultater fra dette pilotprojekt gengives i det følgende.

I et forsøg tog man 2828 selvangivelser med positive eller negative nettoprovener, og brugte en netværksarkitektur med 10 skjulte neuroner, samt 2 outputneuroner repræsenterende henholdsvis positivt eller negativt nettoprovenu. Indlæringen steg jævnt mod 100%, dog måtte der ca. 4000 gennemløb til. Forsøget viser, at det tilsyneladende er muligt for netværket at afdække og »lære« nogle mønstre i data-materialet.

I et andet forsøg anvendtes igen et netværk med 10 skjulte neuroner og 2 outputneuroner. Der blev nu brugt 1472 selvangivelser, lige mange med henholdsvis positive og negative nettoprovener. De 1300 anvendtes til oplæring, og de 172 til test. Oplæringen gik som før problemfrit. Netværkets generaliseringsevne blev testet på den måde, at man undervejs (for hvert gennemløb) stoppede op i indlæringen og testede det partielt oplærte netværk på de 172 testeksempler. Her stabiliserede netværkets generaliseringsevne sig på et niveau på ca. 70 %, d.v.s. at 70 % af testeksemplerne (som dette netværk altså ikke havde set før) kunne forudsiges korrekt. Dette skal sammenlignes med 50 % ved et tilfældigt gæt. Omend dette resultat ikke i sig selv er imponerende, viser det dog, at

der formodentlig er en generaliseringsmulighed. Datamaterialet er trods alt meget begrænset i forhold til en generalisering, idet man faktisk forsøger at dække 113 dimensioner af problemet med kun 1300 eksempler. Med et større datamateriale kunne denne generaliseringsevne formodentligt forbedres.

I et tredie forsøg anvendtes det samme balanceerede datasæt som ovenfor. Netværket bestod igen af 10 skjulte neuroner, men denne gang med kun én outputneuron. Denne skulle angive det korrekte nettoprovnu i kroner (i logaritmisk og skalret form) inden for en tolerance på +/- 10%. Indlæringen steg også her jævnt. Generaliseringsevnen, målt på samme måde som ovenfor, stabiliseredes omkring de 30 %. D.v.s. i 30 % af testeksemplerne var det muligt for netværket at regne sig frem til en værdi, som lå inden for tolerancen. Dette skal sammenlignes med 20 % for et tilfældigt gæt.

Projektdeltagernes konklusion på dette pilotprojekt var dels, at det er muligt at bruge denne teknologi på denne problemstilling, idet det var muligt at lære netværkene en del af de mønstre, der ligger i disse data (d.v.s. en klassificering, som var signifikant bedre end en tilfældig tilordning), og dels at oplæringsmaterialet må forbedres væsentligt, for at netværkene kan nå et brugbart indlæringsniveau. Af samme grund vurderedes det, at de opnåede resultater derfor må betragtes som en nedre grænse for, hvad der er muligt på dette område med neurale netværk.

Et andet problem er, at i oplæringsmaterialet til pilotprojektet indgår *kun* oplysninger fra selvangivelsen. Disse oplysninger er, set med skattevæsenets øjne, me-

get summariske størrelser. En ligning vil typisk også omfatte granskning af det tilhørende virksomhedsskema samt virksomhedens regnskab. For at opnå en bedre generaliseringsevne i netværkene vil det altså være nødvendigt at inddrage yderligere information i oplæringen. Information, som vides at være af betydning for den manuelle ligning, men som ikke er indgået i datamaterialet, f.eks. nøgletal fra regnskabet og »historik«-variable.

Projektets næste fase har til hovedformål at udvikle et egentligt beslutningsstøtteværktøj, der integreres i det administrative miljø, som varetager ligningen. Systemet er, i sin endelige udformning, tænkt som en for- eller efterbehandling af en maskinel eller manuel gennemgang, d.v.s. en hurtigere og/eller mere effektiv *identificering* af de potentielt interessante sager. Dette bør i sidste ende betyde flere provenugivende sager pr. time pr. sagsbehandler (d.v.s. at man »spilder« mindre tid med detaljeret ligning af selvangivelser, som ikke har væsentlige fejl i oplysningerne).

Vurdering af værdipapirer med neurale netværk

Projektet (Dutta & Shekhar, 1989) vedrører udvikling af et neutralt netværk til risikoklassificering af obligationer, d.v.s. der er tale om amerikanske forhold, hvor obligationer kan udstedes af private virksomheder. Det er derfor relevant at vurde disse bl.a. med hensyn til risiko.

Risikoen ved investering i en obligation gives en rating af forskellige uafhængige organisationer. Denne bruges som målestok for risikoen ved investeringer i obligationer, og anvendes bl.a. til at definere til-

ladelige køb for bestemte typer af investorer. Med henblik på at evaluere risikoen foretages en analyse af forskellige forhold ved den udstedende virksomhed, herunder dens evne og villighed til at betale. Der vides generelt meget lidt om, hvorvidt der anvendes modeller (og i givet fald hvilke) til denne vurdering. Situationen kompliceres yderligere, fordi ikke alle de forskellige variable kendes fuldt ud, og at f.eks. villigheden til at betale, påvirkes af et antal forhold, som er svære at karakterisere præcist. Det er derfor vanskeligt præcist at definere en matematisk model, som kan præstere den ønskede rating med den ønskede pålidelighed.

Selve problemstillingen kan opfattes som et *klassificeringsproblem*: Givet et sæt af klasser og et sæt af inputdata (instantieringer), klart beskrevet ved hjælp af et passende sæt af karakteristika, forbindes hvert inputdata-instantiering med en af klasserne.

I dette tilfælde udgør de forskellige obligationsudstedelser sættet af inputdatainstantieringer, og de forskellige ratings udgør det sæt af mulige klasser, til hvilken de enkelte obligationer kan tilhøre. Hver obligationsudstedelse kan beskrives ved et sæt af karakteristika, som repræsenterer finansiell information om den pågældende virksomhed. Det eksakte sæt af karakteristika, som eksperter anvender ved disse vurderinger, kendes ikke præcist, men der findes dog en vis konsensus herom på området.

Til dette projekt er brugt et flerlags-netværk. Der er eksperimentert med 2-lags (d.v.s. uden skjulte lag) og 3-lags-netværk. Valget af struktur i et neutralt netværk er meget afhængigt af domænet. Hvis input-

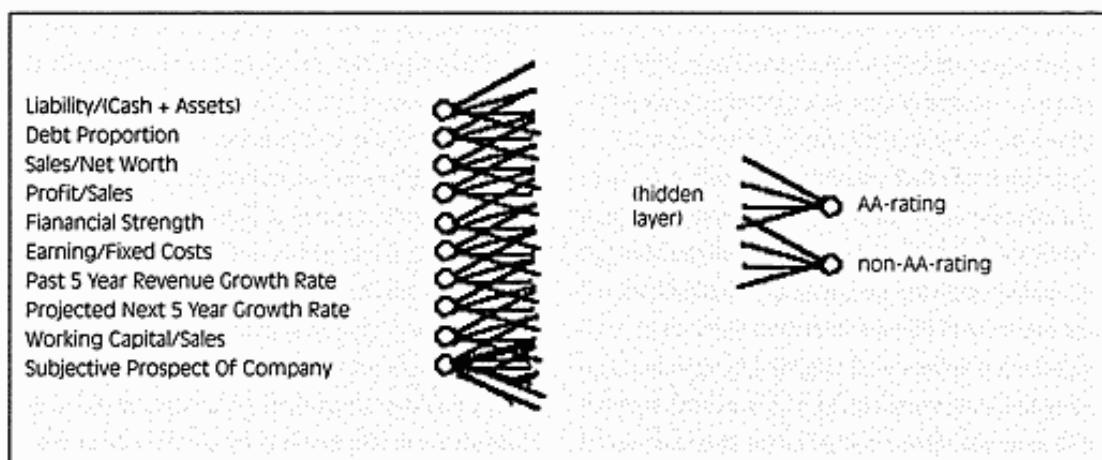
tet består af ekstremt »low level features«, kan der være brug for et stort antal skjulte lag til successivt at ekstrahere »higher order features« fra inputtet. Et lavere antal skjulte lag er tilstrækkeligt, hvis inputtet i sig selv repræsenterer »higher order features«. I dette studie valgte man at bruge »higher order features« (nøgletal) af effektivitetshensyn, og det viste sig, at præstationerne ikke forbedredes signifikant med et højere antal skjulte lag (mere end ét skjult lag).

Valget af variable til dette projekt blev baseret på tidlige studier inden for området, og resultatet blev afgrænset til at skelne mellem AA-ratings (den højeste rating) og ikke-AA-ratings. Modellen (Dutta & Shekhar, 1989), ses side 65.

Der blev udvalgt 47 tilfældige obligationser fra 1986, som alle udløb på samme tidspunkt, fordelt på 30 til oplæring henholdsvis estimering af regressionskoeficienter, og 17 til test. Hovedresultater af forsøgene ses side 65.

De neurale netværk overgik således i dette forsøg konsistent regressionsmodelen med hensyn til præstationer. »Succesraten« (samlet antal rigtige klassifikationer) er generelt betragteligt højere for det neurale netværk end for regressionsanalysen.

Resultaterne fra regressionsanalysen ligger ifølge forfatterne på niveau med tidlige opnåede resultater. Regressionsmodellens relativt dårlige præstationer indikerer ifølge forfatterne, at den lineære multivariate model er inadekvat til forklaring af dette domæne, og at der derfor er væsentlige gevinst ved at anvende neurale netværk på et domæne som dette.



Fase	Klassifikation		% forudsagte		
	aktuelt	model	Regression	2-lags net	3-lags net
Indlæring	AA	AA	61,5	76,9	92,3
	AA	ikke AA	38,5	23,1	7,7
	ikke AA	AA	29,4	17,6	0
	ikke AA	ikke AA	64,8	82,3	100
Test	AA	AA	50	83,3	83,3
	AA	ikke AA	50	16,7	16,7
	ikke AA	AA	27,2	18,1	18,1
	ikke AA	ikke AA	72,8	81,9	81,9

Vurdering

I det ovenstående er præsenteret nogle eksempler på anvendelse af neurale netværk. Mere generelt kan man sige, at den frugtbare anvendelse af neurale netværk i principippet ikke har så meget at gøre med områdets substans, men nærmere med fraværet af gode teorier/modeller, kombineret med adgang til eksemplariske problem-

løsninger og/eller et konsistent erfaringsmateriale.

På nogle domæner findes veldefinerede modeller-teorier, ud fra hvilke det er muligt at foretage god problemløsning (det klassiske eksempel er her elektrisk kredsløbsanalyse). Andre domæner er karakteriseret ved kun at have partielt definerede modeller (her nævnes det medicinske om-

råde, diagnosticering af sygdomme ud fra symptomer og/eller laboratorietests). På sådanne områder har man fundet anvendelse for f.eks. regelbaserede systemer. Endelig findes der domæner, som er karakteriseret ved et næsten komplet fravær af veldefinerede domænemodeller. Her kan konventionelle matematiske teknikker kun vanskeligt anvendes, bl.a. p.gr.a. de krav som sådanne teknikker stiller. Det vil også være vanskeligt at konstruere regelbaserede systemer på sådanne domæner, idet disse stiller krav om dyb viden om domænet.

Det er primært på domæner af sidstnævnte type at neurale netværk muligvis kan finde anvendelse. Bl.a. er neurale netværk generelt non-parametriske, og de stiller mildere krav til de underliggende fordelinger end traditionelle statistiske klassifikatorer. De vil derfor (Dutta, Shekar & Wong, 1992) principielt være mere robuste over for problemstillinger, som indebærer non-lineære processer, ikke-normalfordelt adfærd og »støj« i datamaterialet. Netværkenes adaptive natur tillader også, at modellerne kan adaptere ændringer over tid i modellerne (netværket kan »videreuddannes« med nyt træningsmateriale). Endelig kræves der ikke detaljerede regler for domæneadfærd, men i stedet gode/varierede eksempler på problemløsning. Dette kan vise sig at være en fordel for så vidt at en domæneekspert typisk vil have nemmere ved at fremdrage gode/interessante eksempler på korrekt problemløsning, end at opstille håndfaste regler for sin bedømmelse.

Neurale netværk anvendt i forbindelse med beslutningstøttesystemer kan således potentielt bidrage til at udvide anven-

delsesområderne for sådanne støttesystemer, idet det hermed også er muligt at udvikle systemer på områder, som ikke har nogen veldefineret model.

En svaghed er, at netværkets viden om det generelle mønster findes i en »black-box«-agtig form, d.v.s. i en matrice af numeriske vægte, som ikke på nogen direkte måde relaterer sig til domænespecifikke begreber. Vi kan altså ikke med domænespecifikke begreber forklare, hvilket mønster netværket har lært, eller hvorfor det opfører sig som det gør. En forklaring er kun mulig på niveau af netværkets tekniske primitiver (vægte, indlæringsalgoritmer m.m.). Det er altså ikke direkte muligt at indbygge egentlige forklaringsfaciliteter i et neutralt netværk.

Et andet problematisk forhold er, at trinvis problemløsning ikke er mulig. Neurale netværk er basalt »1-trins-modeller«. I mange problemstillinger indgår mellemregninger, interaktion med omverdenen m.m. som en del af problemløsningsprocessen. Repræsentation af struktureret viden (f.eks. begrebshierarkier) er også ret besværlig. Det mest naturlige er en »flad« repræsentation.

Endelig mangler neurale netværk modularitet. D.v.s. at et givet neutralt netværk er nævert rettet mod løsning af et afgrænsset problem. Skal problemstillingen ændres eller udvides, må man begynde forfra med design og oplæring. Man kan ikke umiddelbart bygge flere oplært netværk sammen.

Endeligt skal det vel også påpeges, at neurale netværk, i lighed med mere konventionelle prognosetechnikker, ikke kan lære »mere« end der ligger i oplæringsmaterialet. Et oplært netværk vil altid genera-

lisere ud fra det lærte, og kan således ikke forudsige f.eks. unikke udviklinger i aktiemarkedet.

Det særegne ved det kunstige neurale netværk er altså, at det principielt er i stand til at finde, lagre (»lære«) og genkende mønstre af langt højere kompleksitet (og uden krav om en eksplisit matematisk model) end det er muligt med f.eks. lineære statistiske teknikker, dog på ret snævert afgrænsede problemområder.

Et neuralt netværk viser således en generaliseringsevne, idet det er i stand til på basis af erfaringsmateriale at finde generelle, komplekse mønstre. Det er endvidere eksperimentelt påvist, at et oplært netværk besidder en kompletteringsevne, d.v.s. det er i stand til ud fra et generelt mønster at foreslå det rigtige output, også selv om inputtet er mangelfuld (et eksempel er genkendelse af et bogstav ud fra en partiell beskrivelse). I tillæg hertil er de relativt robuste over for »støj« og mindre fejl i inputtet, idet netværket vil søge at indpasse tilfældet i det generelle mønster, og herudfra foreslå et output.

Kort sagt kan neurale netværk med en passende arkitektur og oplæring, og med en passende snæver afgrænsning af problemstillingen, generelt bidrage til bedre *forudsigelser* (i bred forstand, fra vurderinger til prognoser), men de kan ikke umiddelbart bidrage til bedre *forklaringer* af sammenhængen i et domæne i en »forståelig« form.

Perspektiver

Perspektiverne for anvendelse af neurale netværk i en erhvervsøkonomisk sammenhæng er mangfoldige. I stort set alle erhvervsøkonomiske sammenhænge kendes

problemstillinger vedr. mangelfulde vurderings- og beslutningsmodeller og utilstrækkelige prognoseværktøjer.

Mere specifikt arbejdes der inden for afsætningsøkonomien med udvikling af salgsprognoseværktøjer baseret på neurale netværk (Dutta & Shekhar, 1992). Inden for produktionsstyring og -planlægning er der udviklet systemer, bl.a. til optimering og overvågning af produktionsprocesser. I finanssektoren anvendes neurale netværk bl.a. til afsløring af potentielle kreditkortmisbrugere.

Generelt ses der en tendens til at afprøve denne teknologi på områder, hvor man traditionelt har benyttet sig af lineære statistiske og operationsanalytiske metoder som en *tilnærmedelse* til det »rigtige«. Men perspektiverne stopper ikke nødvendigvis hermed. I og med at neurale netværk er gode til at finde komplekse mønstre, som ikke kan ses med det blotte øje, kunne man også forestille sig anvendelser inden for f.eks. revision (til gennemsøgning af klientens regnskab for »afvigende« transaktionsmønstre).

Inden for økonomistyringen kunne neurale netværk anvendes til at afdække kritiske forhold »under opscjelling« i virksomheden (en slags »very early warning«). Det kunne være alt fra afvigende udviklinger i detailoplysninger, som ikke umiddelbart fremgår af perioderegnskabets summariske tal, til bemærkelsesværdige samspil af u-sædvanlige omstændigheder/udviklinger i regnskabstallene. Forhold, som muligvis vil undslippe controllerens kritiske analyse.

Forskningen i anvendelse af neurale netværk inden for det erhvervsøkonomiske område må nok siges stadig at befinde sig på et slags pionerstade. Tendensen er,

at man eksperimenterer sig frem til lukrative anvendelsesområder, hvilket også betyder, at der muligvis kan høstes nogle konkurrencemæssige fordele ved at være på forkant med anvendelsesmulighederne for denne teknologi. Et udbygget samarbejde mellem forskningsinstitutioner og virksomheder omkring eksperimentelt prægede projekter af denne art kunne bidrage til et bredere erfahrungsgrundlag, og samtidigt udbrede kendskabet til frugtbare anvendelsesområder for denne teknologi.

Summary

The article gives a basic, non-technical introduction to artificial neural networks. An example is given of the application of neural networks in connection with the going-concern problem. A current Danish project is presented concerning the application of neural networks in connection with tax assessment of income tax returns from sole proprietors, and also an example of neural networks application to the evaluation of firms.

Litteratur

- Dutta, S. & Shekhar, S: An Artificial Intelligence Approach to Predicting Bond Ratings, i: Pau, L.E., Motiwala, J. & Pao, Y.H: eds., *Expert Systems in Economics, Banking and Management* Amsterdam: North-Holland, 1989.
- Dutta, S. & Shekhar, S: *Generalizations with neural networks: An application in the financial domain*, INSEAD, Fontainebleau, France, 1992
- Dutta, S., Shekhar, S. & Wong, W.Y: *Decision support in non-conservative domains: Generalization with neural networks*, INSEAD, Fontainebleau, France, 1992
- Gutknecht, M. & Pfeifer, R.: An approach to integrating expert systems with connectionist networks, pp. 116-127, *AI Communications* vol. 3 no. 3 sept 1990
- Hansen, J.V. & Messier, W.F: Artificial Neural Networks: Foundations and application to a decision problem, pp. 135-141, *Expert Systems With Applications*, vol. 3, 1991
- Mutchler, J.F: A multivariate analysis of the auditor's going-concern opinion decision, pp. 668-682, *Journal of Accounting Research*, 23, 1985
- Rasmussen, K.E: Anvendelse af kunstig intelligens-teknikker på det erhvervsøkonomiske fagområde - et studie af det teoretiske grundlag og et antal praktiske projekter, *Licentiatafhandling*, Handelshøjskole Syd, 1993.
- Rumelhart, D.E. & McClelland, J.L.: *Parallel Distributed Processing*, Vol. 1: Foundations, Cambridge, Massachusetts: *The MIT Press*, 1986
- Stanley, J: *Introduction to Neural Networks*, Sierra Madre, CA: California Scientific Software, 1989

at man eksperimenterer sig frem til lukrative anvendelsesområder, hvilket også betyder, at der muligvis kan høstes nogle konkurrencemæssige fordele ved at være på forkant med anvendelsesmulighederne for denne teknologi. Et udbygget samarbejde mellem forskningsinstitutioner og virksomheder omkring eksperimentelt prægede projekter af denne art kunne bidrage til et bredere erfahrungsgrundlag, og samtidigt udbrede kendskabet til frugtbare anvendelsesområder for denne teknologi.

Summary

The article gives a basic, non-technical introduction to artificial neural networks. An example is given of the application of neural networks in connection with the going-concern problem. A current Danish project is presented concerning the application of neural networks in connection with tax assessment of income tax returns from sole proprietors, and also an example of neural networks application to the evaluation of firms.

Litteratur

- Dutta, S. & Shekhar, S: An Artificial Intelligence Approach to Predicting Bond Ratings, i: Pau, L.E., Motiwala, J. & Pao, Y.H: eds., *Expert Systems in Economics, Banking and Management* Amsterdam: North-Holland, 1989.
- Dutta, S. & Shekhar, S: *Generalizations with neural networks: An application in the financial domain*, INSEAD, Fontainebleau, France, 1992
- Dutta, S., Shekhar, S. & Wong, W.Y: *Decision support in non-conservative domains: Generalization with neural networks*, INSEAD, Fontainebleau, France, 1992
- Gutknecht, M. & Pfeifer, R.: An approach to integrating expert systems with connectionist networks, pp. 116-127, *AI Communications* vol. 3 no. 3 sept 1990
- Hansen, J.V. & Messier, W.F: Artificial Neural Networks: Foundations and application to a decision problem, pp. 135-141, *Expert Systems With Applications*, vol. 3, 1991
- Mutchler, J.F: A multivariate analysis of the auditor's going-concern opinion decision, pp. 668-682, *Journal of Accounting Research*, 23, 1985
- Rasmussen, K.E: Anvendelse af kunstig intelligens-teknikker på det erhvervsøkonomiske fagområde - et studie af det teoretiske grundlag og et antal praktiske projekter, *Licentiatafhandling*, Handelshøjskole Syd, 1993.
- Rumelhart, D.E. & McClelland, J.L.: *Parallel Distributed Processing*, Vol. 1: Foundations, Cambridge, Massachusetts: *The MIT Press*, 1986
- Stanley, J: *Introduction to Neural Networks*, Sierra Madre, CA: California Scientific Software, 1989