

Sammenligning af neuralt net og diskriminantanalyse til genkendelse af ukrudtsfrø

Comparison of neural network and discriminant analysis for weed seed identification

JES KRAGH JENSEN OG POUL ERIK HERLØV PETERSEN

Resumé

Neurale net og diskriminantanalyse blev anvendt til genkendelse af frø fra 11 ukrudtsarter. Klassificeringen blev baseret på de amplituder, der fremkommer ved en analyse af ukrudtsfrøenes kontur ved Fourier transformation. Neurale net artsgenkendte 2,3% til 7,5% flere frø end diskri-

minantanalysen, hvilket ikke blev fundet signifikant. Indflydelsen af antallet af variable på resultaterne ved de 2 metoder blev undersøgt. Et optimum blev fundet hos diskriminantanalysen ved 13-16 variable og hos neuralt net ved 20 variable.

Nøgleord: Genkendelse af ukrudtsfrø, neurale net, diskriminantanalyse, ukrudtsfrøenes kontur, Fourier transformation.

Summary

Neural network and discriminant analysis were used to classify seeds from 11 weed species. The classification was based on the amplitudes resulting by analysis of the weed seed contours using the Fourier transform. The neural network recognized 2.3% to 7.5% more seeds than the dis-

criminant analysis. However this was not found significant. The effect of the number of variable on the classification by the 2 methods was tested. The discriminant analysis showed a classification optimum at 13-16 variable and neural net showed an optimum at 20 variable.

Key words: Weed seed identification, neural network, discriminant analysis, weed seed contours, Fourier transform.

Indledning


Artbestemmelse af ukrudtsfrø foretages rutinemæssigt i forbindelse med frøkontrol og ved undersøgelser af jordens frøbank. Da denne frøidentifikation foregår manuelt, er der en stor interesse for at få automatiseret arbejdet. Maskinel artsbestemmelse kan ske ved anvendelse af billedanalyse (Petersen, 1990 og 1992), hvilket vil sige, at frøbilledet i digital form bearbejdes af en datamat.

Formålet med denne artikel er at sammenligne diskriminantanalysens og neurale nets egenskaber til klassificeringsopgaver, her med udgangspunkt i en artsbestemmelse af ukrudtsfrø baseret på de parametre, der fremkommer ved analyse af ukrudtsfrøenes kontur ved Fourier transformation.

Anvendeligheden af neurale net versus diskriminantanalysen er tidligere blevet undersøgt af Howarth og Searcy (1991) til kvalitetsbestemmelse af gulerødder og af Benediktsson et al. (1990) til klassificering af geografiske data. Teoretisk og empirisk undersøgelse af relationerne mellem neurale net og diskriminantanalysen på simulerede data er udført af Gallinari et al. (1991). Disse tidligere undersøgelser viser, at neurale net besidder egenskaber, der gør metoden til et reelt alternativ til diskriminantanalysen.

Datamaterialet

Som datamateriale blev der anvendt mikroskopbilleder af frø fra 11 ukrudtsarter (tabel 1). Billederne blev optaget med videokamera og digitali-



Figur 1: Øverste figur viser randkurven for frø af fuglegræs, mens nederste figur viser det dertil hørende amplitude spektrum.

The Figure above shows the boundary curve of a chickweed seed, while the Figure below show the amplitude spectrum of this curve.

Tabel 1: Liste over de anvendte ukrudtsarter.
List of weed seed species in this investigation.

Familie	Slægt, art	Dansk navn
<i>Polygonaceae</i>	<i>Rumex acetosa</i>	Almindelig Syre
	<i>Rumex crispus</i>	Kruset Skræppe
	<i>Rumex obtusifolius</i>	Bulbladet Skræppe
	<i>Rumex thyrsiflorus</i>	Dusk-syre
<i>Euphorbiaceae</i>	<i>Euphorbia exigua</i>	Liden Vortemælk
	<i>Euphorbia helioscopia</i>	Skærm-vortemælk
	<i>Euphorbia peplus</i>	Gaffel-vortemælk
<i>Compositae</i>	<i>Chrysanthemum segetum</i>	Gul Okseøj
	<i>Matricaria chamomilla</i>	Vellugtende Kamille
	<i>Matricaria inodora</i>	Lugtløs Kamille
	<i>Matricaria matricarioides</i>	Skive-kamille

seret. Det anvendte billedformat var 512×512 pixels (billedpunkter) hver med 256 gråtoner. En analyse af frøenes konturer blev foretaget ved en Fourier transformation, der opløser randstrukturen i harmoniske svingninger af stigende frekvens og forskellig amplitude (figur 1). De positive frekvenser indeholder informationen om frørandens konkave buer og de negative frekvenser de konvekse buer. Frøidentifikationen sker herefter på baggrund af amplitudespektret fremkommet ved Fourier transformationen (Petersen, 1991).

Betragtes frøets randstruktur beliggende i det komplekse plan, kan koordinaterne x, y beskrives ved de komplekse værdier $x + iy$, hvor $i = \sqrt{-1}$. Dette betyder, at den en-dimensionale Fourier transformation kan anvendes på funktionen $f(t) = x(t) + iy(t)$, hvor t er afstanden fra et givet startpunkt bestemt således, at den totale kurvelængde er N . For en frøkontur vil $x(t), y(t)$ være

$$F(u) = \frac{1}{N} \sum_{t=0}^{N-1} f(t)e^{-i2\pi tu/N} \quad \text{for } u = 0, 1, \dots, N-1 \quad (1)$$

frørandens koordinater til afstanden t .

Fourier transformationen af f er hvor u er frekvensvariablen og N den totale

$$f(t) = \sum_{u=0}^{N-1} F(u)e^{i2\pi tu/N} \quad \text{for } t = 0, 1, \dots, N-1 \quad (2)$$

kurvelængde af frøranden målt i pixels. Den inverse transformation er

Fourier transformationen kan karakteriseres

som en approximation med sinus og cosinus funktioner til en arbitrær funktion. Sinus og cosinus funktionerne udgør en serie svingninger af forskellig frekvens givet ved frekvensvariablen u . Den Fourier transformerede, $F(u)$, består af komplekse tal af typen $a+ib$, hvor normen $(\sqrt{a^2+b^2})$ er lig med amplituden til en given frekvens.

I det foreliggende tilfælde har det været hensigtsmæssigt at ændre intervallet for u til $[-N/2+1, N/2]$ ved en simpel flytning af de sidste $N/2$ værdier af $F(u)$ til den negative akse. Det vil sige at $F(u)=F(u+N)$ for $-N/2 < u < 0$. Desuden er frøets størrelse normaliseret ved at dividere hver $F(u)$ med $c|F(1)|$, hvor c er en frit valgt skaleringskonstant. Herved elimineres frøstørrelsens indflydelse på amplitudens værdi.

Til Fourier transformationen blev 512 randkoordinater bestemt med afstanden $N/512$, hvor N er den totale kurvelængde af frøranden, målt i pixels. Af transformationen 512 Fourier koefficienter anses de koefficienter for u mindre end -128 og større end 128 som støj og blev trunckeret.

Konturanalyserne blev foretaget på frø fra 11 ukrudtsarter (angivet i tabel 1) hver repræsenteret med 25 frø.

Reduktion af antal af variable

Ud fra studier af amplitude spektrene for de implicerede ukrudtsfrø blev det fundet hensigtsmæssigt at summere de negative Fourier koefficienter med de korresponderende positive koefficienter, herved summeres informationen om

Tabel 2: Intervallerne for frekvensvariablen (u) anvendt ved 6 reduktioner af Fourier transformationens amplitudespektrum.
The intervals of the frequency variable (u) used making 6 reductions of the amplitude spectrum.


Intervallerne for Fourier transformationens frekvensvariabel (u).	Reduceringsmetodens navn og antal af variable					
	RED1 27 var.	RED2 24 var.	RED3 20 var.	RED5 16 var.	RED6 13 var.	RED7 8 var.
3	3	3	3	3	3	3
4	4	4	4	4	4	4
5	5	5	5	5	5	5
6	6	6	6	6	6	
7	7	7	7	7	7	
8	8	8	8	8	8	
9	9	9	9	9-10	9-10	6-14
10	10	10	10			
11-12	11-12	11-12	11-12	11-14	11-14	
13-14	13-14	13-14	13-14			
15-16	15-16	15-16	15-16	15-19	15-19	
17-18	17-18	17-18	17-18			15-24
19-20	19-20	19-20	19-20			
21-22	21-22	21-22	21-22	20-24	20-24	
23-24	23-24	23-24	23-24			
25-29	25-29	25-29	25-34	25-34		
30-34	30-34	30-34				
35-39	35-44		35-49	35-44	25-44	25-44
40-44						
45-49	45-54			45-54		
50-54						
55-59	55-64	50-64		55-64	45-64	45-64
60-64						
65-80	65-80	65-96		65-96		
81-96	81-96					
97-102	97-102	97-128			65-128	65-128
103-128	103-128			97-128		

de konvekse og konkave krumninger i frøenes randkurver, og data reduceres til 128 variable (koefficient par).

Da datamaterialet kun bestod af 25 gentagelser fra hver ukrudtsart, hvoraf 6 blev udtaget til testdata, var en yderligere variabel reduktion nødvendig, for opnåelse af maksimal frøidentifikation ved diskriminantanalyse og neurale net. Reduktionen skete ved at tage gennemsnit af amplituderne dannet ved Fourier transformationen af forskellige intervaller af *lul*. Reduktionsmetoden RED7 i tabel 2, blev fra tidligere erfaringer foreslået (Petersen, 1991). For at mindske reduktionsmetodens indflydelse på datainformationens struktur, udspringer alle de øvrige reduk-

tionsmetoder (RED1-RED6) fra systematiske delinger af intervallerne for Fourier transformationens frekvensvariable anvendt ved reduktionsmetoden RED7 (tabel 2).

Data blev delt i et trænings- og testdata, således at hver ukrudtsart blev repræsenteret med 19 frø i træningsdata og 6 frø i testdata. Eksperimentelt blev det fundet, at diskriminantanalysen herved udviste den maximale artsgenkendelsesprocent, således vil sammenligningerne mellem diskriminantanalysen og neurale net ske på diskriminantanalysens præmisser. For data reduceret ved metode RED7 blev opdelingen i trænings- og testdata gentaget 4 gange, således at ingen frø i de 4 testdata var repræsenteret mere end een



Figur 2: Skematisk fremstilling af neuralt net.
Schematic presentation of the neural network.

gang. De 4 trænings- og testdata par benævnes henholdsvis 1,2,3 og 4. De øvrige reducerede data RED1-RED6 blev kun delt i et enkelt trænings- og testdata par svarende til deling nr.1.

Metoder

Neural net

Klassifikationen blev udført med det kommercielt tilgængelige neurale net program, BrainMaker Professional (BrainMaker, 1989). Programmet er et menustyret program med en veludbygget grafisk brugerflade, som gør programmet umiddelbart nemt at bruge. De mere fundamentale funktioner i programmet, såsom indlæringsalgoritmen, godkendelsesmetoden og netarkitekturen, er det ikke muligt at omdefinere, hvilket begrænser programmets anvendelsesområder.

Indlæringsproceduren for BrainMaker programmet bygger på backpropagation algoritmen.

Backpropagation er en kontrolleret iterativ indlæringsmetode, der ved en gradientsøgende teknik minimerer residual middelværdisummen (MSE) mellem ønsket uddata og predikteret uddata. Mindskelsen af MSE opnåes ved en justering af værdierne for forbindelserne mellem neuronerne (vægtene), bestemt ud fra en tilbagekalkulation (backpropagation) af uddatafejlen til de foregående neuronlag.

I det neurale net i BrainMaker kan neuronerne i et lag kun have forbindelse med det foregående eller det efterfølgende neuronlag (figur 2), således at »det skjulte lag« kun modtager data fra inddata-laget og uddata-laget modtager data fra »det skjulte lag«. Forbindelsen mellem hver af neuronlagene udgøres af elementerne i en reel tal vægt-matrix, kaldet W . Forbindelsen mellem neuron j og neuron k angives ved w_{jk} .

Hvis det ønskes at træne det neurale net med data indeholdende N observationer, består den

p 'te observation af en inddata- og referencevektor (benævnt henholdsvis ind_p og ref_p). Indlæringen i det neurale net sker ved en iterativ regulering af vægtene w , sådan at det neurale net til sidst opnår en tilstand, hvor net-uddata vektoren for ind_p , kaldet ud_p , approksimerer ref_p for alle værdier af p . Ved træningsstart vil ud_p ikke approksimere ref_p , og denne afvigelse kan for en neuron k tilhørende uddata-laget defineres ved fejlparametren:

$$Fejl_{pi} \equiv 1/2(ref_{pk} - ud_{pk})^2 \quad (3)$$

Den totale fejl for observationen p er da:

$$Fejl_p \equiv 1/2 \sum_k (ref_{pk} - ud_{pk})^2 \quad (4)$$

og den totale fejl, $Fejl_{tot}$, for alle observationer i træningssættet er da summen af $Fejl_p$ for p gående fra 1 til N .

Træningen af det neurale net kan derfor opfattes som et minimeringsproblem, hvor målet er at minimere $Fejl_{tot}$ ved ændringer i de uafhængige variable, som vægtmatrixens elementer w udgør. Minimeringen af $Fejl_{tot}$ sker ved brug af en algoritme, der i små trin søger mod den stejlest faldende gradient på en flade i det rum vægtmatrixen udspejler, hvor højden i ethvert punkt på fladen i dette rum er lig med den til vægtmatrixen W knyttede $Fejl_{tot}$. En ulempe ved denne minimeringsmetode er, at algoritmen kan blive fanget i et lokalt minimum, i stedet for at finde det globale minimum, som er målet (Stanley og Luedeking, 1990).

Den aktuelle minimeringsalgoritme implementeret i BrainMaker er tidligere brugt af Sejnowski og Roswenberg (1986)

$$\Delta_p W_{ij} = \lambda((1 - \mu)\delta_{pj} ud_{pi} + \mu\Delta_{p-1} w_{ij}), \quad (5)$$

hvor $\Delta_p W_{ij}$ udtrykker ændringen af vægten mellem neuron i og j ved inddata p . λ er en konstant, kaldet indlæringsraten, som bestemmer størrelsen af vægtreguleringen. Udglatningsfaktor μ angiver i hvilken grad den aktuelle vægtjustering skal afhænge af den foregående ændring af vægtene, og herved mindskes risikoen dels for en indfangelse i et lokalt $Fejl_{tot}$ minimum, og dels at justeringen af vægtene svinger mellem 2 permanente tilstande, hvilke kaldes vægt-oscillation. Ved inddata p kaldes uddata ud_{pi} fra den i 'te

neuron, og δ_{pj} angiver fejlaktiviteten for neuron j i det foregående lag ved inddata p .

Bestemmelsen af fejlaktiviteterne involverer 2 faser. Ved den første fase udbredes inddata fremad i nettet, resulterende i uddata ud_{pj} for hver uddata neuron. Udbredelsen af inddata i nettet er bestemt af en sigmoid overføringsfunktion hvor η , også kaldet *Gain*, bestemmer hældningen af sigmoid

$$TF(a_j) = \frac{1}{1 + e^{(-\eta(\sum_i w_{ij} TF(a_i) - \Theta))}}, \quad (6)$$

funktionen. Θ kaldes centerparametren og angiver centreringen af sigmoidfunktionen. Θ antages oftest værdien 0. a_{pj} udtrykker aktiviteten af den j 'te neuron og den p 'te observation defineret ved summen af det vægtede uddata fra det foregående neuronlag i

$$a_{pj} = \sum_i w_{ij} TF(a_{pi}). \quad (7)$$

Ved sammenligning af uddata ud_{pk} med reference data ref_p bestemmes størrelsen af den fejl, der er knyttet til hver uddata-neuron. Aktivitetsfejlen δ_{pk} til neuron k tilhørende uddata-laget kan beskrives ved

$$\delta_{pk} = (ref_{pk} - ud_{pk})TF^{-1}(a_{pk}). \quad (8)$$

Den anden fase involverer en tilbagekalkulation af $Fejl_p$. Først udregnes vægtændringen Δw_{jk} ved formel (5) på baggrund af aktivitetsfejlene δ_{pk} . Herefter kan aktivitetsfejlene δ_{pj} for det foregående neuronlag beregnes ved


$$d_{pj} = TF^{-1}(a_{pj}) \sum_k -d_{pk} w_{jk}. \quad (9)$$

Estimationen af aktivitetsfejlene for de neuroner, der ikke er knyttet til uddata-laget, og derfor ikke har et specificeret referencegrundlag, sker altså på baggrund af aktivitetsfejlene knyttet til de neuroner i det efterfølgende neuronlag, som de direkte er i forbindelse med og vægtene af disse forbindelser.


Neural net optimering

Inden træningen af det neurale netværk påbegyndes, må antallet af neuroner, netparametre og træningsstrategien fastsættes.

Den optimale størrelse, bestemt ved antallet af skjulte neuroner et neuralt net skal have for at løse en given applikation, er afhængig af datama-



Figur 3: Fordelingen af vægtene W ved træning af neural net med for få (5) skjulte neuroner.
Distribution of the weights W after training the neural net using too few (5) neurons in the hidden layer.



Figur 4: Fordelingen af vægtene W ved træning af neural net med korrekt antal (10) skjulte neuroner.
Distribution of the weights W after training the neural net using an accurate number (10) of neurons in the hidden layer.

teriale, og må derfor bestemmes ud fra empiriske overvejelser og erfaringer. For få neuroner i det skjulte lag vil resultere i en reduceret indlæringssevne, da vægtenes værdier bliver meget spredte i forhold til hinanden (figur 3 og 4). Spredningen af vægtværdierne betyder, at visse inddata-neuroner tillægges en så stor indflydelse, at inddata til disse neuroner bliver dominerende for uddata, og prediktionen vil blive unuanceret. Er det skjulte neuronlag for stort, vil det resultere i en nedsættelse af generalisationsevnen og indlæringshastigheden. Er et neural net mistænkt for at indeholde for mange neuroner, kan en *pruning* gavne på generalisationsevnen. *Pruning* betyder, at de vægte W_{ij} der antager værdier under et fastlagt niveau, sættes og fastholdes til 0, hvilket svarer til en brydning af forbindelsen mellem de implicerede neuroner. Umiddelbart efter *pruning* vil det neurale net tabe en del af den indlærte information, men vil sandsynligvis hurtigt kunne genoptrænes ved justering af de vægte, der ikke fastholdes til 0. Niveauet for *pruning* kan langsomt sættes til større og større værdier, indtil en genoptræning begynder at udeblive.

Træningsraten λ , der kan antage værdier mellem 1 og 0, er af fundamental betydning for træningshastigheden. En generel regel for fastsættelse af træningsrate er, at den skal antage størst værdi i starten og gradvist nedsættes i takt med indlæringen. En for høj indlæringsrate vil bevirke oscillation, hvilket viser sig ved, at antallet af indlærte datapar ikke stiger med træningen,

men hopper mellem et antal af værdier. Hvis indlæringsraten derimod er for lav, vil den negative gradientsøgende algoritme have større risiko for indfangelse i et lokalt minimum.

Den sigmoide overføringsfunktionens hældning udtrykt ved η kan øge det neurale nets evne til adskillelse af data. Antager η en værdi mindre end 1, vil sigmoidfunktionen approksimere en lineær funktion, hvilket kan være en fordel ved klassifikationer, hvor der ikke kræves en markant adskillelse mellem grupperne. Antager η en værdi noget større end 1, vil sigmoidfunktionen tilnærme sig en stepfunktion, hvilket bruges ved logistik-applikationer.

Ved træning af neurale net ønskes det normalt, at det neurale net skal udtrække de generelle træk, der er knyttet til træningsdata, således at nettet med relevans kan bruges til analyse af andre data end træningsdata. En for intensiv træning af det neurale net kan resultere i, at det neurale net bliver for specifikt, hvorved generalisationsevnen nedsættes. Dette fænomen kaldes for *overfitting*. For at finde den maksimale indlærning og undgå *overfitting* er det vigtigt under træningen at starte med en moderat træningstolerance, der angiver den variation, der accepteres mellem prediktionen og referencen. Når indlæringen af træningssættet stagnerer, testes netværket og lagres. Denne procedure gentages med lavere og lavere træningstolerance, så længe artsgenkendelsen i testsættet stiger eller er uforandret. Ved visse datamaterialer kan det være en

Tabel 3: Klassifikationsresultater på træningsdata med 8 variable (RED7) ved neural net og diskriminantanalyse.
Classification results of training data using 8 variables (RED 7) in neural net and discriminant analysis, respectively.

	Trænings- og testsæt nr.	Antal fejlklas- sificeret af 209 obs.	Procent fejlklas- sificeret	Gennemsnit- lige fejllige- klassifika- tioner i procent
Neurale Netværk	1	18	8,6	8,2
	2	17	8,1	
	3	21	10,0	
	4	13	6,2	
Diskrimi- nant- analysen	1	27	12,9	12,5
	2	25	12,0	
	3	22	10,5	
	4	30	14,4	

fordel at tilføre støj til inddata i træningssættet, hvorved det neurale net kun udtrækker de mest specifikke informationer fra data, hvilket giver en øget generalisationsevne.

Struktur og opsætning af neural net til applikationen

Strukturen af det neurale net, anvendt til de foreliggende klassifikationsopgaver, havde 1 neuron i inddata-laget for hver variabel, 10 neuroner i det skjulte-lag og 11 neuroner i uddata-laget, svarende til de 11 ukrudtsarter. Ved træningsstart blev vægtene W_{ij} randomiseret i intervallet -2 til 2 og η , der bestemmer hældningen af den sigmoidale overføringsfunktion, fastsættes til $0,700$. Indlæringsraten λ antager startværdien $0,5$ og nedsættes trinvis til $0,005$ i takt med indlæringen af observationerne stiger. Træningstolerancen var ved start $0,48$ og efter indlæringsstagnation nedsat til $0,4$, hvorefter træningen genoptages. Efter endt træning blev nettet *pruned*, men uden eller med negativ resultat til følge, hvilket antyder, at neuronantallet var nær optimalt.

I denne applikation er hver af neuronerne i uddata-laget defineret til at repræsentere en af de 11 ukrudtsarter. Inddata blev klassificeret til den art, som knyttede sig til den mest aktive neuron i uddata-laget. BrainMaker angiver antallet af rig-

Tabel 4: Anvendelse af neural net og diskriminantanalyse til artsgenkendelse på reduceret testsæt med 8 parametre (RED7).
Neural net and discriminant analysis applied for identification of species using 8 variables in test set (RED7).

	Trænings- og testsæt nr.	Antal genken- delses- fejl ved 66 obs.	Procent genken- delses- fejl	Gennemsnit- lige fejl- genkendte i procent
Neurale Netværk	1	11	16,7	15,9
	2	14	21,2	
	3	8	12,1	
	4	9	13,6	
Diskrimi- nant- analysen	1	13	19,7	18,2
	2	15	22,7	
	3	8	12,1	
	4	12	18,2	

tige klassificerede, men imidlertid angives kun de klassificerede, som ligger over en given tolerancetærskel. Det var derfor nødvendigt ved test af nettet at udskrive inddata og uddata for derefter at finde den faktiske genkendelsesfejl.

Diskriminantanalysen


Klassificering af ukrudtsfrøene ud fra de reducerede data, blev også foretaget ved lineær diskriminantanalyse med krydsvalidering. Det blev her antaget, at data var multivariat normalfordelt med ens kovariansmatricer for de enkelte ukrudtsarter (Seber, 1984). Beregningerne blev foretaget ved hjælp af proceduren Proc Discrim i SAS (SAS, 1987).

Resultater

Klassifikation af træningsdata RED7 med 8 variable er vist i tabel 3 for neural net og diskriminantanalysen. Efter endt træning klassificerede det neurale net i gennemsnit for de 4 dataopdelinger $8,2\%$ til forkerte arter. Diskriminantanalysen fejlklassificerede i gennemsnit $12,5\%$ af træningsdata. Det neurale net adskilte altså træningsdata $4,3\%$ bedre end diskriminantanalysen.

Resultaterne for det neurale nets og for diskri-

Procent fejl



Figur 5: Artsgenkendelsesfejl som funktion af antallet af variable i trænings- og testdata.
Identification error as a function of number of variables in training and test set.

mininantanalysens genkendelse af ukrudtsarterne, udført på testdata med 8 parametre (RED7) og gentaget for de 4 forskellige dataopdelinger, er vist i tabel 4. Genkendelsesfejlen ved neurale net var i gennemsnit 15,9% og ved diskriminantanalysen 18,2% i gennemsnit. Neurale net opnåede altså en forbedret frøgenkendelse i gennemsnit på 2,3%. Testes resultaterne fra neurale net og diskriminantanalysen mod hinanden ved en parvis T-test (Rudemo, 1979) blev P-værdien 10%. Det betyder, at der ved 8 parametre ikke blev fundet nogen signifikant forskel på de 2 analyser, men kun en tendens til dette. Den øgede genkendelsesprocent opnået ved neurale net, skyldes, som det fremgår af tabel 3, at det neurale net på baggrund af træningdata bedre har kunnet udskille relevant information. Det forbedrede re-

sultat ved neurale net skyldes ikke tilfældig opstået tilpasning af vægtmatrixen til testdata.

Undersøgelse af det neurale nets og diskriminantanalysens følsomhed over for antallet af parametre i datasættet (figur 5) viste, at det neurale net havde et optimum for antal variable, der lå væsentligt højere end diskriminantanalysens. Det bedste resultat opnåede diskriminantanalysen ved et variabelantal mellem 13 og 16, mens genkendelsesfejlen for det neurale net faldt jævnt indtil 20 variable. Fra 20 til 24 variable var der en kraftig stigning i fejlgenkendelsen igen, således at ved de 24 variable var resultatet som ved 8 variable. Denne stigning i genkendelsesfejlen fra 20 til 24 variable kan skyldes reduktionsmetoden. Klassifikationsresultaterne ved data med 16 variable (diskriminantanalysens optimum) fra de

2 analyser, blev testet ved McNemar's test (*Armitage*, 1971). Statistisk blev der ikke fundet en signifikant forskel på de 2 metoder, men en tendens hertil, da P-værdien var 14,4%.

Diskussion og konklusion

Neurale net har i denne artikel vist sig at være lige så anvendelig som diskriminantanalyse ved klassificeringsopgaver. Det neurale net klassificerede arterne i træningsdata med 8 variable gennemsnitligt 4,3% bedre end diskriminantanalysen. På basis af dette opnåede det neurale net på testdata generelt en bedre artgenkendelsesprocent end diskriminantanalysen. Resultatforskellen på 2,3% var dog ikke signifikant i en T-test. Grundlaget for testen er dog spinkelt, da der kun indgik 4 observationer. Det må konkluderes, at antallet af observationer i datamaterialet er i underkanten til statistisk at afdække forskellen mellem neurale nets og diskriminantanalysens anvendelighed til klassifikation. Fra lignende undersøgelser er det også blevet rapporteret, at det neurale net klarer klassificeringsopgaver bedre end diskriminantanalysen. *Howarth og Searcy* (1991) opnåede således en nedsættelse af fejklassifikationen på henholdsvis 1,2% og 9,9% ved bestemmelse af gulerødders kvalitet (kurvede og knækkede).

Det neurale net og diskriminantanalysen responderede forskelligt over for antallet af inddata variable. Diskriminantanalysen nåede relativt tidligt sit optimum, hvorimod det neurale net med fordel kunne udnytte et større antal datavariable. Det neurale net udviste en faldende fejlprocent ved inddata på 8 til 20 variable, men steg kraftigt igen ved 24 variable. Stigningen i fejlprocenten udtrykker ikke alene det neurale nets følsomhed over for antallet af variable, men nok informationsmængden pr. variabel og dermed datareduktionsmetoden. Variabelforøgelsen for inddata mellem 20 og 24 variable er opnået ved en halvering af frekvensvariabel-intervallerne knyttet til den sidste del af spektret, hvor informationsmængden formodes at være mindst. Den største forskel i genkendelsesprocenten ved neurale net og diskriminantanalysen var 7,5% ved anvendelse af 20 variable.

Neurale net har her vist tendenser til at udføre klassifikation bedre end diskriminantanalysen. Dette resultat betyder dog ikke, at det neurale net udkonkurrerer diskriminantanalysen, da

hver metode har sine fordele og ulemper.

Fordele ved det neurale net er:

- at det er i stand til at klare non-lineære problemer (*Rumelhart og McClelland*, 1988)
- at det giver information om datamaterialets struktur, ved studie af vægtmatricen.
- at det kan modellere på *multisource* data, uden vægtning af de enkelte faktoreres pålidelighed.
- at det er i stand til at udtrække større information fra data med flere variable end diskriminantanalysen.

Ulemperne ved neural net er:

- at træningsproceduren kan være tidskrævende.
- at træningsoptimum ikke er fast defineret, men findes ved gentagende testninger. Dette betyder, at resultaterne kan være vanskelige at reproducere.
- at træningsvariable og antal neuroner skal optimeres.

Anvendelsen af et kommercielt tilgængeligt neuralt netværks-program har vist sig brugbar til denne klassificeringsopgave, selv om der var funktioner, der enten var manglende eller uden for brugerens indflydelse. En ændring af det neurale nets godkendelsesprocedure ved træning og testning ville her have lettet arbejdet væsentligt, og muligvis have givet bedre resultater. Valget af det neurale nets fejlminimeringsalgoritme er i *BrainMaker* ikke særlig specialiseret, hvilket på den ene side øger anvendelsesområdet, men på den anden side måske ikke er det helt optimale til klassificeringsapplikationer af denne type.

Litteraturliste:

- Armitage, P.* 1971: Statistical Methods in Medical Research. Blackwell Scientific Publications.
- Benediktsson, J. A.; Swain, P. H. & Ersoy, O. K.* 1990: Neural Network Approaches Versus Statistical Methods in Classification of Multisource Remote Sensing Data. IEEE Transactions on Geoscience and Remote Sensing, Vol 28. nr. 4, side 540-551.
- BrainMaker*, 1989: Neural Network Simulation Software, Users Guide and Reference Manual. California Scientific Software.
- Gallinari, P.; Thiria, S.; Badran, F. & Fogelman-Soulie, F.* 1991: On the Relations Between Discriminant Analysis and Multilayer Perceptrons. Neural Networks, Vol. 4, side 349-360.
- Howard, M. S. & Searcy, S. W.* 1991: Comparison of Bayesian and Neural Network Classifiers for Grading Carrots. An ASAE meeting presentation, paper

- No. 91-70. American Society of Agricultural Engineers.
- Petersen, P. E. H.* 1990: Billedanalyse af ukrudtsfrø. Temadag om *Biometri og Informatik* 1990, Tidsskrift for Planteavl. Beretning nr. S 2053, side 83-94.
- Petersen, P. E. H.* 1991: Shape Analysis of Weed Seeds Using the Fourier Transform. Proceedings of The 7th Scandinavian Conference on Image Analysis. Vol 1, side 56-63.
- Petersen P. E. H.*, 1992: Weed Seed Identification by shape and Texture Analysis of Microscope Images. Ph.D.dissertation. Tidsskrift for Planteavl. Beretning nr. S 2198.
- Rudemo, M.* 1979: Statistik og sandsynlighedslære med biologiske anvendelser, del 2. Varians- og regressionsanalyse, sampling. DSR Forlag.
- Rumelhart, D. E. & McClelland, J. L.* 1988: Parallel Distributed Processing. Explorations in the Microstructure of Cognition. Vol.1. Foundations. The MIT Press.
- SAS*, 1987: SAS/STAT Guide for Personal Computers. Version 6 Edition. SAS Institute Inc., Cary NC.
- Seber, G. A. F.* 1984: Multivariate Observations. Wiley series in probability and mathematical statistics.
- Sejnowski, T. & Rosenberg, C.* 1986: NetTalk: A Parallel Network That Learns to Read Aloud. Neurocomputing.
- Stanley, J. & Luedeking, S.* 1990: Introduction to Neural Networks. *California Scientific Software*.

Manuskript modtaget d. 29. juli 1992