

Institut für Landwirtschaftliche Betriebslehre der
Rheinischen Friedrich-Wilhelms-Universität Bonn

**Klassifizierung landwirtschaftlicher
Jahresabschlüsse mittels Neuronaler Netze und
Fuzzy Systeme**

Inaugural - Dissertation

zur Erlangung des Grades
Doktor der Agrarwissenschaften
(Dr. agr.)

der
Hohen Landwirtschaftlichen Fakultät
der
Rheinischen Friedrich-Wilhelms-Universität
zu Bonn

Vorgelegt am: 29.06.2001

von
Henner Löbbe
aus
Hamm

Klassifizierung landwirtschaftlicher Jahresabschlüsse mittels Neuronaler Netze und Fuzzy Systeme

Kurzfassung

Henner Löbbe

In der Jahresabschlussanalyse kommen zunehmend empirisch-statistische Methoden zum Einsatz. Hierbei handelt es sich um Verfahren, die Unternehmen nach Ereignissen bzw. Zuständen klassifizieren. Aufgrund ihrer Eigenschaften haben sich in den letzten Jahren insbesondere Neuronale Netze für diese Aufgabe durchgesetzt. Ihre überlegenen Eigenschaften gegenüber anderen empirisch-statistischen Instrumenten sind: Lernfähigkeit, Generalisierbarkeit und Fehlertoleranz.

Deshalb werden in dieser Arbeit Neuronale Netze verwendet, um auf der Grundlage von Buchführungsdaten die zukünftigen finanziellen Zustände landwirtschaftlicher Unternehmen zu klassifizieren. Die Klassen des finanziellen Zustandes sind "finanziell gefährdet" und "finanziell gesund". Bei der Klassifizierung tritt das Problem auf, dass die Unternehmen nicht empirisch eindeutig der jeweiligen Klasse zugeordnet werden können. Deswegen werden die Klassen anhand der Kennzahlen Gesamtkapitalrentabilität, Fremdkapitalanteil und dynamischer Verschuldungsgrad definiert. Die beiden finanziellen Zustände sind des weiteren nicht eindeutig gegeneinander abgrenzbar. Deshalb erfolgt die Zuordnung der Unternehmen zur jeweiligen Klasse über ein Fuzzy System.

Bei der Klassifizierung der zukünftigen finanziellen Zustände wird wiederum auf dieses Fuzzy System zurückgegriffen. Das Klassifizierungsmodell wird deshalb in die Abschnitte Neuronale Netze und Fuzzy Systeme unterteilt. Die Neuronalen Netze klassifizieren die Unternehmen nach den drei Kennzahlen, die den finanziellen Zustand definieren. Für jede Variable wird ein eigenes Neuronales Netz entwickelt. Hierbei handelt es sich jeweils um ein dreilagiges Multilayer-Perceptron mit einem Backpropagation-Lernalgorithmus. Über das Fuzzy System werden die klassifizierten Output-Variablen zusammengefasst.

Durch diese Aufteilung des Modells werden die Eigenschaften der beiden Instrumente Neuronale Netze und Fuzzy Systeme miteinander kombiniert, da diese sich ergänzen. Neuronale Netze können strukturelle, vollständig unbekannte Systeme beherrschen, soweit deren Eingabe- und Ausgabeverhalten bekannt ist. Deshalb werden sie für den Teil des Modells verwendet, bei dem kein Wissen über die Zusammenhänge der Ausgangsdaten vorliegt. Im Gegensatz hierzu kann das Fuzzy System das vage Wissen über die Zusammenhänge der drei definierenden Kennzahlen über die Fuzzy Regeln mitberücksichtigen.

Zur Überprüfung, ob die theoretischen Vorteile des Modells in der Praxis zu besseren Klassifizierungsergebnissen führen, wird ein Vergleich zwischen den Ergebnissen dieses Modells mit einer multivariaten Diskriminanzanalyse vorgenommen. Hierbei kann gezeigt werden, dass dieses Modell bessere Ergebnisse liefert als bisherige Verfahren.

Classification of agricultural balance sheets by Neural Networks and Fuzzy Systems

Summary

Henner Löbbe

Empirical-statistical methods are increasingly used in the balance sheet analysis. These are methods which classify companies according to events and conditions respectively. In the recent years, especially Neural Networks have established themselves for this task on the basis of their qualities. Their superior attributes vis-a-vis other empirical-statistical instruments are: adaptability, generalization and fault tolerance.

Therefore, in this study Neural Networks are used in order to classify the future financial states of agricultural companies on the basis of accounting data. The classes of the financial state are "financial distress" and "financial health". No unambiguous empirical assignment of the classes can be determined. For that reason, the classes are defined by the ratios: return on assets, debt-asset ratio and dynamic indebtedness (debt-cash flow ratio). The two financial states are furthermore not clearly definable against each other. Therefore, the assignment of the companies to the respective class is made via a Fuzzy System.

This Fuzzy System is again used for the classification of the future financial states. Therefore, the classification-model is subdivided into the sections of Neural Networks and Fuzzy Systems. The Neural Networks classify the companies according to the three ratios which define the financial state. An individual Neural Network is developed for each variable. This is, in each case, a three-layered Multilayer-Perceptron with a Backpropagation-Algorithm. The classified output variables are summarised through the Fuzzy System.

By subdividing the model, the attributes of the two instruments are combined, since they complement each other. Neural Networks can recognize structural, completely unknown systems, as far as their input and output behaviour known. For that reason, they are used for that part of the model for which no knowledge of the connections of the data is available. In contrast to the Neural Networks, the Fuzzy System can consider the vague knowledge of the connections of the three defining ratios by the Fuzzy rules.

To examine whether the theoretical advantages of the model lead to better results in practice, the results of this model are compared with a multiple discriminant analysis. Thus it can be shown that this model delivers better classification results than previous methods.

Inhaltsverzeichnis

1	Einleitung	1
1.1	Problemstellung	1
1.2	Zielsetzung und Arbeitsschwerpunkte	3
2	Rechnungswesen und Jahresabschlussanalyse in der Landwirtschaft	5
2.1	Buchführung.....	5
2.1.1	Aufgaben der Buchführung.....	6
2.1.2	Buchführung in der Landwirtschaft.....	7
2.2	Grundlagen der Jahresabschlussanalyse	8
2.3	Bilanz und Vermögensbewertung.....	10
2.4	Aufgabenstellung der Jahresabschlussanalyse	14
2.5	Jahresabschlussanalysen als Kontrollsysteme und Finanzanalysen .	15
2.5.1	Prozess der Finanzkontrolle.....	16
2.5.2	Betriebsvergleich als Kontrollinstrument	17
2.5.3	Auswahl von Kennzahlen für den Betriebsvergleich	18
2.5.4	Zielkonflikt zwischen Rentabilität und Stabilität.....	20
2.5.5	Beispiel für ein Verfahren der Finanzkontrolle	22
2.6	Ansätze der Jahresabschlusskennzahlenanalyse	23
2.6.1	Traditionelle Kennzahlenanalyse.....	23
2.6.2	Kennzahlenvergleich.....	24
2.6.2.1	Kennzahlenarten.....	24
2.6.2.2	Struktur der Kennzahlen.....	26
2.6.2.3	Kennzahlenrechnung als Vergleichsrechnung	27
2.6.2.4	Kennzahlensystem.....	32
2.6.3	Neuere Ansätze der Jahresabschlussanalyse	34
2.6.3.1	Diskriminanzanalyse	36
2.6.3.2	Neuronale Netze.....	41
2.7	Die Grenzen der Jahresabschlussanalyse	43
2.8	Fazit	46

3	Die Instrumente Neuronale Netze (NN) und Fuzzy Systeme (FS)	48
3.1	Theorie und Modellbau	48
3.2	Die statistische Jahresabschlussanalyse als Modell	53
3.3	Die Mustererkennung	57
3.4	Neuronale Netze (NN)	59
3.4.1	Hintergrund	59
3.4.2	Anwendungsfelder Neuronaler Netze in der Betriebswirtschaft	61
3.4.3	Geschichtliche Entwicklung der Neuronalen Netze	63
3.4.4	Grundlagen eines biologischen Neuronalen Netzes	65
3.4.5	Allgemeine Eigenschaften der künstlichen Neuronalen Netze	67
3.4.6	Prinzipien künstlicher Neuronaler Netze	69
3.4.6.1	Das Neuron	70
3.4.6.2	Das Verbindungsnetzwerk	76
3.4.6.3	Lernalgorithmen	82
3.4.6.3.1	Probleme beim Backpropagation-Lernverfahren	92
3.4.6.3.2	Möglichkeiten zur Behebung der Problematiken	95
3.4.7	Backpropagation und statistische Funktionsanpassung	98
3.4.8	Der LVQ als weiteren Lernalgorithmus für Klassifizierungsprobleme	101
3.4.9	Übertraining und Generalisierung Neuronaler Netze	105
3.4.10	Fazit	107
3.5	Fuzzy Systeme (FS)	109
3.5.1	Einführung	109
3.5.2	Der Begriff der unscharfen Mengen	113
3.5.3	Fuzzy-Mengen Operationen und ihre Eigenschaften	120
3.5.4	Berechnung von Fuzzy-Inferenzen	124
3.5.5	Defuzzifizierung	131
3.5.6	Fazit	133
3.6	Kombination Neuronaler Netze und Fuzzy Systeme	135

4	<i>Modellentwicklung eines Fuzzy Neuronalen-Netzes (FNN-Modell)</i>	137
4.1	Beschreibung des zugrundeliegenden Datenmaterials	137
4.1.1	Allgemeine Ausführungen.....	137
4.1.2	Dateneinteilung	139
4.1.3	Die Struktur der ausgewählten Buchführungsdaten	140
4.1.4	Festlegung des Kennzahlenkatalogs	143
4.1.4.1	Output-Variablen.....	143
4.1.4.1.1	Auswahl der Output-Variablen.....	144
4.1.4.1.2	Verteilung der Output-Variablen	149
4.1.4.1.3	Erstellung von Fuzzy Mengen.....	153
4.1.4.2	Input-Variablen.....	156
4.2	Klassifizierung landwirtschaftlicher Jahresabschlüsse	165
4.2.1	Software für das FNN	165
4.2.2	Aufbau des Modells	166
4.2.3	Entwicklung und Optimierung eines FNN-Modells.....	167
4.2.3.1	Auswahl des NN.....	167
4.2.3.2	Architektur des verwendeten Neuronalen Netzes.....	169
4.2.3.3	Parametereinstellung	172
4.2.3.4	Optimierung des Netzwerkes	174
4.2.4	Bildung des Ereignisses der finanziellen Gefährdung aus mehreren Kennzahlen.....	177
4.2.5	Aufbau des Fuzzy Systems.....	178
4.3	Ermittlung der Klassifizierungsergebnisse	185
4.4	Fazit	190
5	<i>Vergleich Fuzzy Neuronaler Netze mit einer Diskriminanzanalyse</i>	192
5.1	Auswahl der Vergleichsmethode	192
5.2	Vergleich des Fuzzy Neuronalen Netzes mit einer Diskriminanzanalyse	193
5.2.1	Anwendungsvoraussetzungen für die MDA.....	195
5.2.2	Mögliche Konsequenz für die Praxis	197
5.3	Fazit	199
6	<i>Zusammenfassung</i>	201

Verzeichnis der Abbildungen

Abb. 1: Scoring-Verfahren der FmHA	22
Abb. 2: Systematik der Jahreskennzahlenanalyse	23
Abb. 3: Einteilung von Kennzahlen.....	25
Abb. 4: Informationsbereiche der Kennzahlenanalyse	27
Abb. 5: Fähigkeiten Neuronaler Netze	42
Abb. 6: Datenaggregation zu Wissen	48
Abb. 7: Erkenntnisgewinnung und Modellisomorphie	51
Abb. 8: Mustererkennungsprozess.....	58
Abb. 9: Nervensystem.....	65
Abb. 10: Dimension der Komplexität.....	68
Abb. 11: Darstellung eines künstlichen Neurons	71
Abb. 12: Schwellenwertfunktion: eine Heaviside Sprungfunktion.....	72
Abb. 13: Semilineare Funktion	73
Abb. 14: Häufig verwendete Aktivierungs- bzw. Ausgabefunktionen.....	74
Abb. 15: Neuron mit Bias - Eingang.....	75
Abb. 16: Mehrschichtiges Neuronales Netz.....	78
Abb. 17: Beispiel-Topologien und ihre Verbindungsmatrizen.....	79
Abb. 18: Fehlerverlaufskurve I	85
Abb. 19: Fehlerfläche für zwei Gewichtsveränderungen.....	86
Abb. 20: Fehlerverlaufskurve II	86
Abb. 21: Fehlerverlaufskurve III	87
Abb. 22: Lokales Minimum	93
Abb. 23: Flaches Plateau.....	93
Abb. 24: Direktes Oszillieren	94
Abb. 25: Indirektes Oszillieren.....	94
Abb. 26: Verlassen guter Minima	95
Abb. 27: Backpropagation-Netze als Funktionen	99
Abb. 28: Lineare Annäherung an die Trainingsmenge.....	99
Abb. 29: Aufbau eines LVQ.....	105

Abb. 30: Das Phänomen des Übertrainings.....	106
Abb. 31: Zugehörigkeitsfunktion der Fuzzy Menge "durchschnittliche Gesamtkapitalrentabilität"	117
Abb. 32: Zugehörigkeitsfunktion der Fuzzy Menge "unterdurchschnittliche Gesamtkapitalrentabilität"	117
Abb. 33: Zugehörigkeitsfunktion der Fuzzy Menge "überdurchschnittliche Gesamtkapitalrentabilität"	117
Abb. 34: Linguistische Variable "Gesamtkapitalrentabilität"	118
Abb. 35: Schnittmenge (Min-Operator).....	121
Abb. 36: Vereinigungsmenge (Max-Operator).....	122
Abb. 37: Max-prod-Inferenz.....	129
Abb. 38: Max-Min-Inferenz	130
Abb. 39: Unscharfe Schlussfolgerung für die "finanzielle Gesundheit".....	130
Abb. 40: Flächenschwerpunktmethode	132
Abb. 41: Aufbau eines Fuzzy Systems (FS)	133
Abb. 42: Vor- und Nachteile der NN und der FS	136
Abb. 43: Verteilung der Output-Variablen "Gesamtkapitalrentabilität"	149
Abb. 44: Verteilung der Output-Variablen "Fremdkapitalanteil"	151
Abb. 45: Verteilung der Outputvariablen "dynamischer Verschuldungsgrad"	152
Abb. 46: Zugehörigkeitsfunktion für die Gesamtkapitalrentabilität	155
Abb. 47: Zugehörigkeitsfunktion für den dynamischen Verschuldungsgrad.....	157
Abb. 48: Aufbau des FNN Modells als MLP	167
Abb. 49: Aufbau eines MLP (schematisch)	170
Abb. 50: Kompensatorische Wirkung für zwei Output-Variablen	184
Abb. 51: Zugehörigkeitsfunktionen der Klassen finanziell gefährdet und gesund	186

Verzeichnis der Tabellen

Tab. 1: Beispiel für die Problematik bei der Kennzahlenanalyse.....	31
Tab. 2: Beispiel einer DuPont-Kennzahlenanalyse für zwei Landwirte.....	33
Tab. 3: Zielsetzung und Struktur der beiden Modelle	49
Tab. 4: Beispiele für Regeln mit Anwendung des "fuzzy-und".....	127
Tab. 5: Aufteilung der Unternehmen	139
Tab. 6: Datenverteilung	140
Tab. 7: Verteilungsmaße der absoluten Kennzahlen (Auszug).....	141
Tab. 8: Kennwerte: Gesamtkapitalrentabilität	150
Tab. 9: Kennwerte: Fremdkapitalanteil	151
Tab. 10: Kennwerte: Dynamischer Verschuldungsgrad	152
Tab. 11: Input-Kennzahlen: Ertrag/Rentabilität	158
Tab. 12: Input-Kennzahlen: Wachstum und Finanzierungskraft.....	160
Tab. 13: Input-Kennzahlen: Vermögens- und Kapitalanalyse.....	162
Tab. 14: Input-Kennzahlen: finanziellen Effizienz	164
Tab. 15: Parametereinstellungen für das NN.....	173
Tab. 16: MSE für die ersten Parametereinstellungen.....	173
Tab. 17: Aussortierte Input-Variablen im FNN-Modell	175
Tab. 18: MSE-Werte bei unterschiedlicher Neuronenanzahl im Hidden-Layer.....	177
Tab. 19: Regeln für die Beschreibung der finanziellen Situation	181
Tab. 20: Korrelationsmatrix	182
Tab. 21: Kombinationsmöglichkeiten der Regeln	183
Tab. 22: Klassifizierungsergebnisse	188
Tab. 23: Ergebnisse der MDA	194
Tab. 24: Input-Variablen für MDA	197

Verzeichnis der Abkürzungen

BMELF	Bundesministerium für Ernährung, Landwirtschaft und Forsten
CoM	Centroiden-Methode
DBV	Deutscher Bauerverband
DOF	Degree of fulfillment
FK	Fremdkapital
FmHA	Farmers Home Administration
FNN	fuzzy Neuronales Netz
FS	Fuzzy System
GA	genetischer Algorithmus
HGB	Handelsgesetzbuch
IEEE	Institute of Electrical and Electronics Engineers
KI	Künstliche Intelligenz
LF	Landwirtschaftliche Fläche
LVQ	Learning Vector Quantizer
MDA	multivariate Diskriminanzanalyse
MLP	Multilayer-Prezeptron
MSE	mean square error (mittlere quadratische Abweichung)
NN	Neuronales Netz
ROA	Return on Assets
ROI	Return of Investment
RMS	root mean square (Wurzel der mittleren quadratischen Abweichung)
SNNS	Stuttgarter Neuronale Netze Simulator
SPSS	Statistical Package for the Social Sciences
Wj	Wirtschaftsjahr

1 Einleitung

1.1 Problemstellung

Durch den Strukturwandel in der Landwirtschaft wachsen die verbleibenden Unternehmen (vgl. Deutscher Bauernverband, Situationsbericht 2000). Dieses beschleunigte Wachstum können die Unternehmen nicht aus eigenen Mitteln finanzieren, da die Eigenkapitalbildung geringer ist als der Finanzbedarf für die notwendigen Investitionen. Deshalb wachsen die Unternehmen vorwiegend durch Fremdkapital. Hierdurch verringert sich die finanzielle Stabilität.

Wegen der Instabilität der finanziellen Zustände von landwirtschaftlichen Unternehmen wird zukünftig die *Früherkennung* von finanziellen Fehlentwicklungen an Bedeutung gewinnen. Bei dem Einsatz von funktionsfähigen Instrumenten können frühzeitig Korrekturen in den Unternehmen vorgenommen werden. Neben den externen Faktoren (Prognosen für den Absatz-, den Faktormarkt, die Agrarpolitik und die gesellschaftliche Bedürfnisse), auf die das Unternehmen direkt keinen Einfluss hat, wird die Vorausschätzung der Ertragskraft und finanziellen Stabilität des Unternehmens immer wichtiger.

Die meisten bisher entwickelten Früherkennungssysteme verwenden den Jahresabschluss als Informationsquelle. In diesem Fall handelt es sich bei den Früherkennungssystemen um Jahresabschlussanalysen. Diese Vorgehensweise erscheint problematisch, weil der Jahresabschluss erst spät als Informationsgrundlage zur Verfügung steht und nicht originär als Früherkennungsinstrument entwickelt worden ist (vgl. WAGNER, 1992). Aber oftmals bildet die Jahresabschlussanalyse den Ausgangspunkt einer Früherkennung und dient als erster Ansatzpunkt einer tiefergreifenden Ursachenforschung. Somit bietet die Jahresabschlussanalyse aufgrund der vorhandenen Daten eine kostengünstige Alternative zur ständigen Kontrolle der Finanzsituation (RADTKE, 1993, S.9).

Für die *Jahresabschlussanalyse* werden teilweise formalisierte Verfahren eingesetzt, die darauf abzielen, die Früherkennung zu objektivieren und zu rationalisieren (KRAUSE, 1993, S.1). Die bisher in der Praxis eingesetzten Verfahren beruhen häufig auf den Erfahrungen menschlicher Experten, die uneinheitlich, subjektiv und teilweise schwer nachvollziehbar sind (HENO, 1983, S.1).

Bei den bisher eingesetzten formalisierten Verfahren handelt es sich um mathematisch-statistische Ansätze. Das in den 80er und Anfang 90er Jahren am häufigsten und erfolgreichsten eingesetzte mathematisch-statistische Verfahren war die *multivariate Diskriminanzanalyse* (MDA) (vgl. ALTMAN und SAUNDERS, 1998).

Durch eine enorme Weiterentwicklung anderer empirisch-induktiver Verfahren, wie die der *Neuronalen Netze*, wurden diese alternativ zu den MDA verwendet. Die Neuronalen Netze (NN) müssen weniger Anwendungsvoraussetzungen als die MDA erfüllen, was jahrelang ein Kritikpunkt gegenüber der Leistungsfähigkeit der MDA war. Zusätzlich berücksichtigen die NN Nichtlinearitäten in der Datenstruktur, so dass die MDA teilweise erfolgreich durch die NN ersetzt wurde (vgl. WONG, 2000). Die Ergebnisse der NN als mathematisch-statistische Jahresabschlussanalyse erzielen zwar keinen Quantensprung gegenüber den bisherigen Verfahren, führen aber in den meisten Fällen zu einer besseren Klassifizierungsleistung (KERLING und PODDIG, 1994, S. 484). Außerdem werden die NN ständig weiterentwickelt und verbessert. Sie verfügen somit über weitreichende Verbesserungspotentiale.

Bei der Anwendung von NN als Klassifizierungsinstrument in der mathematisch-statistischen Jahresabschlussanalyse taucht das Problem auf, dass dieses Verfahren als empirisch-induktives Verfahren die empirisch beobachtbaren Ereignisse klassifiziert. Da aber der finanzielle Zustand eines Unternehmens indirekt anhand von Kennzahlen beschrieben wird und nicht eindeutig durch empirische Daten erfassbar ist, handelt es sich hierbei um eine unscharfe Analyse. Die bisherigen Einstufungen des finanziellen Zustandes eines Unternehmens erfolgt über Kennzahlenintervalle (vgl. KASTENS und FEATHERSTONE, 1999). Dieses unscharfe Wissen über den finanziellen Zustand eines Unternehmens kann am besten durch *Fuzzy Systeme* (FS) beschrieben werden.

NN und FS weisen als Methode unterschiedliche Vor- und Nachteile auf. Aufgrund ihrer ergänzenden Eigenschaften lassen sie eine vielfältige Form an Kombinationen als sinnvoll erscheinen (NAUCK et al., 1994, S. 259). Derartige Kombinationen haben das Ziel, das Gesamtergebnis zu verbessern. Aus diesem Grund wird in dieser Arbeit für die empirisch-induktive Jahresabschlussanalyse ein Modell aus NN und FS entwickelt.

1.2 Zielsetzung und Arbeitsschwerpunkte

Das Ziel dieser Arbeit ist, ein Modell zu entwickeln, das gegenüber den bisherigen Instrumenten die Klassifizierungsgüte und die Anwendungsmöglichkeiten, wie die Klassifizierung von unscharfen Ereignissen, verbessert. Hierzu soll die Aufteilung der Klassifizierung in ein selbstlernendes Instrument, dem NN, und die Nutzung von vorhandenem unscharfem Wissen durch den Einsatz eines FS erfolgen. Aufgrund der großen Bedeutung der Datengrundlage für empirisch-induktive Klassifizierungsinstrumente erfolgt eine detaillierte Analyse der verwendeten Daten.

Die NN sind in der Lage, anhand der Datengrundlage Strukturzusammenhänge zwischen den Kennzahlen und deren Bedeutung für die finanzielle Gefährdung zu erlernen. Sie können sich anhand der Kennzahlen Wissen über eine mögliche zukünftige finanzielle Gefährdung aneignen, welches die Klassifizierungsleistung verbessert.

Das zu klassifizierende Ereignis "finanzielle Gefährdung", muss über Kennzahlen definiert werden, weil es empirisch nicht erfassbar ist. Dieses Wissen über die Definition des Ereignisses wird für eine bessere Klassifizierungsleistung genutzt. Um die Höhe der finanziellen Gefährdung der Unternehmen ausdrücken zu können, werden hierfür die unscharfen Ergebnisse des FS verwendet. Durch die unscharfen Grenzen zwischen den beiden Klassen "finanziell gefährdet" und "finanziell gesund" liefert dieses System zusätzliche Informationen über den Grad der Gefährdung.

Um die Zusammenhänge zwischen der Früherkennung, der Jahresabschlussanalyse, den Neuronalen Netzen (NN) und den Fuzzy Systemen (FS) besser darstellen zu können, wird diese Forschungsarbeit in drei Schwerpunkte unterteilt. Der erste Teil (*Kapitel 2*) stellt die bisherigen *Jahresabschlussanalysen* vor. Hier soll herausgearbeitet werden, welche Bedeutung die Jahresabschlussanalyse für die Ermittlung der finanziellen Gefährdung hat und wo die Stärken und Schwächen in der Jahresabschlussanalyse liegen.

Der zweite Teil (*Kapitel 3*) soll das neue Klassifizierungsinstrument "*Neuronale Netze (NN)*" und das Analyseinstrument "*Fuzzy Systeme (FS)*" für die Jahresabschlussanalyse näher erläutern. Hierfür werden zuerst die beiden neuen Instrumente hinsichtlich ihrer theoretischen Ansätze und Anwendungsmöglichkeiten beschrieben. Zusätzlich erfolgt eine Beschreibung der Stärken und Schwächen dieser Instrumente und die Kombinationsmöglichkeiten zu einem Modell für die Ermittlung der finanziellen Gefährdung von landwirtschaftlichen Unternehmen.

Im dritten Teil (*Kapitel 4 und 5*) wird das entwickelte Modell anhand von empirischen Jahresabschlüssen auf den praktischen Einsatz getestet. Die hier ermittelten Ergebnisse werden danach mit bisher erfolgreich eingesetzten mathematisch-statistischen Jahresabschlussanalysen verglichen. Neben dem quantitativen Vergleich

der Klassifizierungsleistung wird hier insbesondere ein qualitativer Vergleich der Vor- und Nachteile der beiden Klassifizierungsinstrumente durchgeführt.

Im Anschluss an den Vergleich der Instrumente wird ein Ausblick über die weiteren Entwicklungsmöglichkeiten der NN und FS in der künftigen Jahresabschlussanalyse und die weiteren Anwendungen in der Betriebswirtschaft gegeben.

Im einzelnen handelt es sich bei dem hier entwickelten Modell um einen Klassifikator für Jahresabschlüsse mittels NN und FS. Das zu klassifizierende Ereignis ist die *"finanzielle Gefährdung"* der landwirtschaftlichen Unternehmen in zukünftigen Wirtschaftsjahren. Die Klassen werden eingeteilt in *"finanziell gefährdet"* und *"finanziell gesund"*.

2 Rechnungswesen und Jahresabschlussanalyse in der Landwirtschaft

Der Jahresabschluss ist eine anerkannte Datengrundlage für die Beurteilung der finanziellen Situation eines Unternehmens. Die auf dem Jahresabschluss aufbauende Jahresabschlussanalyse dient der Beurteilung eines Unternehmens und stellt heutzutage ein wichtiges Kontrollinstrument und Informationssystem des finanziellen Zustands eines Unternehmens dar.

2.1 Buchführung

Für das Management eines landwirtschaftlichen Unternehmens ist die Entwicklung eines zeitnahen und umfassenden Informationssystems notwendig. Dieses soll dem Entscheidungsträger als Kontrolle und zur Verbesserung der finanziellen Leistung des Unternehmens dienen. Es stellt die vergangene Unternehmenstätigkeit in Zahlen dar. Aus diesen Informationen sollen u.a. die zukünftigen Entwicklungen des Unternehmens abgeleitet und Entscheidungen getroffen werden (BARRY et al., 2000, S.43).

Aus der allgemeinen Sicht ist die Aufgabe des *Rechnungswesens* die Erfassung sowie Aufbereitung und Auswertung aller quantifizierter Unternehmensdaten (COENENBERG, 1988, S.8). Erfassungssystem und damit Ausgangspunkt des betrieblichen Rechnungswesens ist die Buchhaltung bzw. Buchführung (KOSIOL, 1976, S.35). Diese bilden die realen Vorgänge des Wirtschaftsgeschehens eines Unternehmens durch ein System von Zahlen ab, soweit sich diese rechnerisch ausdrücken lassen (WEBER, 1974, S.3ff.). Wird das Rechnungswesen auf den Aspekt der Datenerfassung verkürzt, beschreiben die Begriffe Rechnungswesen und Buchführung aufgrund der dargestellten Verzahnung das gleiche Aufgabengebiet.

Die Daten der *Buchführung* informieren die Unternehmensleitung über den Ablauf des Wirtschaftsprozesses und bilden eine wichtige Informationsbasis für die Unternehmensführung. Die Buchführung misst die wirtschaftlichen Aktivitäten. Um als Messverfahren eingesetzt werden zu können, muss sie die verschiedenen Vorgänge des Wirtschaftsgeschehens messbar und damit vergleichbar machen. Dafür ist es erforderlich, dass die am Wirtschaftsprozess beteiligten, unterschiedlich realen und physischen Größen und deren Bewegungen durch eine einheitliche Größe abgebildet werden. In der Buchführung dient das Geld als Maßeinheit. Soweit möglich, werden reale in nominale Vorgänge überführt und durch eine Menge von Geldeinheiten dargestellt. Nicht die Beschaffung und die Kombination unterschiedlicher Einsatzgüter zu absatzreifen Leistungen oder die Verwertung dieser Leistungen wird abgebildet, sondern eine Parallelerscheinung, welche diesem Prozess gegenläufig entspricht und sich in zuzuordnenden Zahlungsbewegungen dokumentiert (SCHULZE, 1966, S.114). Durch das Konstrukt der Zahlungsbewegungen lassen sich auch solche Vorgänge darstellen, denen keine reale Güterbewegung zugrunde liegen (FELSCHER, 1988,

S.133). Die monetäre Darstellung dient als Messgrundlage für das wirtschaftliche Geschehen.

Der monetär ausgerichtete Teil der Buchführung wird als Finanzbuchführung bezeichnet. Diese nimmt aufgrund ihres Charakters als Messgrundlage auch innerhalb der landwirtschaftlichen Buchführung eine besondere Stellung ein (BRANDES und WOERMANN, 1971, S.78). Neben den monetären Größen befinden sich in der landwirtschaftlichen Buchführung auch Mengenangaben nicht monetärer Größen (beispielsweise Angaben zur Flächenausstattung, Viehbesatz, nicht entlohnte Familienarbeitskräfte). Mengenangaben sind aber im Buchungssatz nicht obligatorisch mitzuführen (DLG-Arbeitsunterlagen, 1989, S.29). Die Verlässlichkeit der Mengenangaben ist dadurch eingeschränkt.

Von den Teilen, die nicht monetär bewertet werden, wird abstrahiert, dass sie für das monetäre Bewertungssystem unbedeutend sind (KOSIOL, 1976, S.51). Damit wird die komplexe wirtschaftliche Realität des Unternehmens auf ein vereinfachendes gedankliches Gebilde reduziert. In diesem Sinne hat die Buchführung den Charakter eines Modells. Die durch eine Abstraktion gewonnene vereinfachte Abbildung der Wirklichkeit, ermöglicht überhaupt erst eine gedankliche Durchdringung der komplexen Realität (KOSIOL, 1964, S.754).

Damit das Modell die Aufgabe als Erkenntnismittel erfüllen kann und gültige Aussagen über den Untersuchungsgegenstand abgeleitet werden können, muss trotz aller Vereinfachungen die Abbildung bestimmten Anforderungen an die Ähnlichkeit zwischen Modell und Original genügen. Die Ähnlichkeitsanforderungen sind in der Literatur in unterschiedlicher Weise näher spezifiziert. Die strengste Anforderung verlangt, dass das Modell eine isomorphe Abbildung vom Original sei (DINKELBACH, 1973, S.161).

2.1.1 Aufgaben der Buchführung

Die eigentliche interne Funktion der Buchführung und der darauf beruhenden Jahresabschlussanalyse ist, Informationen über den Betrieb zu gewinnen und diese transparent zu machen. Diese Informationsfunktion dient vorwiegend einer Informationsverdichtung und bezweckt die Aktivierung des Aussagegehalts des eigenen Jahresabschlusses im Hinblick auf spezifische betriebliche Fragestellungen.

Andere Funktionen des Jahresabschlusses sind die Kontrollfunktionen. Hier soll durch eine Analyse die Schwachstellenforschung und -überwindung durchgeführt werden. Aber auch als Instrument zur Erkennung und Nutzung von Chancen ist die Jahresabschlussanalyse ein geeignetes Instrument (KÜTING und WEBER, 1994, S.14).

Die Buchführung hat häufig nicht nur diese Aufgaben, sondern sie dient auch folgenden privat- und volkswirtschaftlichen Zwecken:

privatwirtschaftlich:

- Buchführung aus Gründen der *Einkommensteuer*: Die Buchführung ist an sich die Standardform und die korrekteste Methode zur steuerlichen Gewinnermittlung. Die weiteren, vom Einkommensteuerrecht zulässigen Methoden der Gewinnermittlung sind Ersatzmethoden und sind nur für kleinere Betriebe vorgesehen.
- *Kontrollfunktion*: Übersicht über den Stand und die Entwicklung auf einzelnen Konten, Festlegung des Erfolges und seiner Ursachen, Übersicht über das Betriebsvermögen und seine Veränderung.
- *Datengrundlage für ex-post-Kalkulationen*: Vergangenheitsbezogene Kalkulationen, wie zum Beispiel der Überblick über die Liquiditätsentwicklung und Kosten-Leistungs-Rechnung.
- *Datengrundlage für Planungen*: Zukunftsbezogene Kalkulationen.
- *Nachweisfunktion*: Nachweis der wirtschaftlichen Situation gegenüber Kreditgebern.

volkswirtschaftlich:

- Bereitstellung von Daten für die Agrarpolitik (Betriebsvergleiche und Statistiken)
- Basis für das Kreditwesen und Versicherungen
- Grundlage der Besteuerung

2.1.2 Buchführung in der Landwirtschaft

In Deutschland führten 1996 - 1999 durchschnittlich rund 180.000 landwirtschaftliche Unternehmen Bücher (vgl. Deutscher Bauernverband, 1999). Das entspricht einem Anteil von rund 35% an der Gesamtzahl der landwirtschaftlichen Unternehmen. Es haben sich im wesentlichen drei Formen der Arbeitsteilung herausgebildet, die als Organisationsformen bezeichnet werden.

Dabei werden unterschieden:

- die außerbetriebliche Buchführung,
- die verbundene Buchführung
- und die innerbetriebliche Buchführung.

In der Landwirtschaft herrscht die außerbetriebliche Buchführung vor (vgl. LAND-DATA, 1999). Die verbundene und die innerbetriebliche Buchführung haben nur eine geringe Bedeutung.

Der Datenfluss in der Buchführung ist immer gleich. Es werden Daten in ein EDV-System eingegeben und gespeichert. Bei Bedarf können dann laufend oder zu bestimmten Stichtagen definierte Auswertungen abgerufen werden. Diese setzen nur voraus, dass die Daten im erforderlichen Umfang und in der erforderlichen Struktur vorliegen.

Durch die große Anzahl an Jahresabschlüssen bei einzelnen Datenverarbeitern steht sowohl dem Landwirt als auch für statistische Auswertungen ein umfangreicher Datenpool für Vergleichszwecke zur Verfügung (vgl. LAND-DATA, 1999).

In der Landwirtschaft existiert ein weitgehend einheitlicher Jahresabschluss (vgl. MANTHEY, 1995). Der Vorteil eines formal und inhaltlich einheitlichen Jahresabschlusses ist nicht nur, dass damit viele Statistiken (EU, Bund, Bundesländer, Landwirtschaftskammern und Verbände) erstellt werden können, sondern dass auch der einzelne Landwirt selbst über horizontale und vertikale Betriebsvergleiche verfügt. Über Buchstellen und Datenverarbeiter hinweg sind hierdurch bessere betriebliche Vergleiche möglich. Das Beratungswesen profitiert durch die Möglichkeit der Standardisierung von Jahresabschlüssen. Mit Hilfe dieser Datengrundlage sind schnelle und günstige Betriebsvergleiche anzufertigen. Ein formal und inhaltlich einheitlicher Jahresabschluss ist somit für alle am Rechnungswesen Beteiligten vorteilhaft (vgl. MANTHEY, 1995).

Durch diese einheitliche Datengrundlage der Jahresabschlüsse und die zentrale Verarbeitung der Daten bestehen hervorragende Möglichkeiten zur Erstellung von aufschlussreichen vertikalen Jahresabschlussanalysen, die dem einzelnen Betriebsleiter als ein wichtiges Unternehmensführungsinstrument dienen.

2.2 Grundlagen der Jahresabschlussanalyse

Unter *Jahresabschlussanalyse* ist die Aufbereitung (Verdichtung) sowie die Auswertung erkenntniszielorientierter Unternehmensinformationen mittels Kennzahlen, Kennzahlensystemen und sonstiger Methoden zu verstehen. Das Erkenntnisziel der Jahresabschlussanalyse ist dabei die Erlangung eines den tatsächlichen Verhältnissen entsprechenden Bildes der wirtschaftlichen Lage, konkret der Vermögens-, Finanz- und Ertragslage eines Unternehmens. Auf dieser Grundlage soll die Beurteilung des Unternehmens in seiner Gesamtheit ermöglicht werden (REHKUGLER und PODDIG, 1993, S.9).

Die Aufarbeitung (Verdichtung) der Informationen beschäftigt sich vorrangig mit einer bloßen Neuordnung (Umformung) der ansonsten nur schwer überschaubaren Informationsfülle. So sieht RIEBELL in der Jahresabschlussanalyse das Zerlegen und Aufgliedern der Bilanz sowie die Gewinn- und Verlustrechnung. Zur Bilanzanalyse gehört dabei das systematische Übertragen der Bilanz- und Erfolgszahlen in ein sachgerechtes Bilanzauswertungsschema; dieses wird dann strukturiert, d.h. durch Prozent- und andere Kennzahlen ergänzt (RIEBELL, 1992, S.137).

Nach COENENBERG wird mit der Jahresabschlussanalyse "... ein Verfahren der Informationsgewinnung und -auswertung bezeichnet, mit dessen Hilfe aus den Angaben des Jahresabschlusses ... Erkenntnisse über die Finanz- und Ertragslage der Unternehmen gewonnen werden" (COENENBERG, 1992, S.547). Etwas allgemeiner meint LEFFSON: "Die Jahresabschlussanalyse besteht im Zerlegen von Jahresabschlüssen in seine Komponenten zur einer Beurteilung der Unternehmung anhand der auf diese Weise erlangten Informationen" (LEFFSON, 1984, S.3).

Nach einer weiteren Definition von KERTH und WOLF wird im Rahmen der Jahresabschlussanalyse "das Zahlenmaterial einer Bilanz in seine strukturbestimmenden Elemente zerlegt, die, in sinnvolle Beziehungen zueinander oder zu Vergleichszahlen gesetzt, einen Einblick in die wirtschaftlichen Verhältnisse der bilanzierenden Unternehmen vermitteln" (KERTH und WOLF, 1986, S.21f.). KRUMNOW schließlich sieht in der Bilanzanalyse "die Beurteilung von Unternehmen anhand von Informationen, die durch die Aufgliederung und Aufbereitung von Jahresabschlüssen in deren Einzelelemente sowie sachlogisch zusammenhängende Komponenten und Relationen gewonnen werden" (KRUMNOW, 1985, S.783).

Die Jahresabschlussanalyse versteht sich - auf eine Kurzformel gebracht - als eine verdichtete Informationsermittlung. Sie ist zunächst ein Prozess der Informationsgewinnung und dem anschließenden Neuordnen der im Jahresabschluss enthaltenen Informationen. Der Begriff "Bilanzanalyse" bezieht sich auf die Analyse des gesamten Jahresabschlusses und nicht nur auf die Bilanz. Es sollte daher konsequenterweise von einer "Jahresabschlussanalyse" gesprochen werden. "Bilanzanalyse" meint also "Jahresabschlussanalyse" (REHKUGLER und PODDIG, 1993, S.9)

Die Bestandteile einer Jahresabschlussanalyse sind die Bilanzanalyse und die Gewinn- und Verlustrechnung. Die *Bilanz* zeigt die Vermögensgegenstände und deren Bewertung sowie die Aufteilung des Kapitals zwischen eigen und fremd auf. Die Bilanz wird nur zu bestimmten Stichtagen (z.B. 30.06.) ermittelt und ist somit anfällig für verschönernde Bilanzpolitiken. Die *Gewinn- und Verlustrechnung* ist eine Zusammenfassung der betrieblichen Geschäftstätigkeit über eine Periode hinweg. Diese Periode liegt gewöhnlich zwischen den beiden Stichtagen der Bilanzanalyse.

Für die Landwirtschaft ist das in der Regel der 01.07. und 30.06. Die Stichtage sind in der landwirtschaftlichen Buchführung von der Natur aus vorgegeben. Zu diesem Zeitpunkt sind die Lager der Unternehmen am wenigsten gefüllt, da eine neue Ernte kurz bevorsteht.

2.3 Bilanz und Vermögensbewertung

Die Jahresabschlussanalyse besteht aus der Analyse Gewinn und Verlustrechnung und der Bilanz. Die Ergebnisse der Bilanzanalyse sind stark durch die Vermögensbewertung beeinflusst. Aus diesem Grund werden hier die Prinzipien und Probleme dieser Bewertung näher durchleuchtet.

In der Bilanz sind das Anlagevermögen, das Umlaufvermögen, das Eigenkapital, die Schulden sowie die Rechnungsabgrenzungsposten gesondert auszuweisen und hinreichend aufzugliedern (§ 247 Abs. 1 HGB). Das Vermögen ist auf der linken Seite und das Kapital auf der rechten aufgeführt. Insgesamt entspricht das Vermögen minus Verbindlichkeiten dem Eigenkapital.

Das Vermögen ist nach gebundenen Fristigkeiten unterteilt. Es lassen sich grob drei Klassen unterteilen:

- das *Umlaufvermögen*, das in kürzester Zeit zu Bargeld gemacht werden kann, ohne dass größere Verluste gegenüber dem ausgewiesenen Wert realisiert werden können,
- das *Viehvermögen*, das sowohl Umlaufvermögen wie Anlagevermögen sein kann, je nachdem um welche Tiere es sich handelt,
- das *Anlagevermögen*, das über mehrere Jahre gebunden ist und meistens kurzfristig nur mit einem erheblichen Wertverlust zu verkaufen ist.

Unter den folgenden Bewertungsprinzipien wird der Wert des jeweiligen Vermögens ermittelt:

1. *Vorsichtsprinzip*: Es ist vorsichtig zu bewerten, namentlich sind alle vorhersehbaren Risiken und Verluste, die zum Abschlussstichtag entstanden sind, zu berücksichtigen, selbst wenn diese erst nach dem Abschlussstichtag anfallen bzw. am Tag der Aufstellung des Jahresabschlusses bekannt geworden sind; Gewinne sind nur zu berücksichtigen, wenn sie realisiert worden sind (§ 252 Abs. 1 Nr. 4 HGB). Das Prinzip der kaufmännischen Vorsicht stellt ein fundamentales Grundprinzip dar. Es dient zuallererst dem Gläubigerschutz, indem es eine hohe Bewertung vermeidet. Daraus leiten sich weitere Prinzipien ab (BODMER und HEIßENHUBER, 1993, S: 55).
2. *Realisationsprinzip*: Dem Prinzip der Vorsicht entsprechend werden Wertsteigerungen erst ausgewiesen, wenn sie realisiert worden sind.
3. *Imparitätsprinzip*: Entsprechend dem Vorsichtsprinzip wird das Realisationsprinzip bei der Ausweisung von Verlusten durchbrochen, d.h. Verluste werden bereits vor ihrer rechtlichen und finanzwirtschaftlichen Realisierung ausgewiesen, während die Gewinne nur erfasst werden, wenn sie realisiert wurden bzw. wenn ein Rechtsanspruch besteht. Es erfolgt also eine Ungleichbehandlung der Bewertung noch nicht realisierter Gewinne und Verluste. Für die Bewertung der Vermögenspositionen gilt somit das *Niedrigstwertprinzip* und für die Bewertung der Passivposten ist das *Höchstwertprinzip* anzuwenden.

Hierbei ist ein hoher Gläubigerschutz festzustellen. Dementsprechend sind im weiteren Verlauf die Vermögenswerte und vor allem das Eigenkapital zu bewerten.

Neben den angeführten Prinzipien sind noch weitere Gesichtspunkte zu beachten (BODMER und HEIßENHUBER; 1993, S.56):

1. *Bilanzidentität*: Es besteht ein strenger Wertzusammenhang zwischen der Schlussbilanz des Vorjahres und der Anfangsbilanz des darauffolgenden Jahres.
2. *Methodenstetigkeit*: Bewertungsmethoden des Vorjahres müssen in der Regel beibehalten werden.

Nachfolgend sind die Besonderheiten bei der Vermögensbewertung in der Landwirtschaft, insbesondere für den betriebswirtschaftlichen Jahresabschluss aufgeführt. Diese Bewertung erfolgt nach den Anschaffungs-/Herstellungskosten. Vermögensgegenstände sind höchstens mit den Anschaffungs-/Herstellungskosten, vermindert um die Abschreibung, anzusetzen (§ 253 Abs. 2 HGB).

Probleme bei der Vermögensbewertung

Bei der *Verwendung der Herstellungskosten* im landwirtschaftlichen Rechnungswesen taucht das Problem auf, dass nur in wenigen landwirtschaftlichen Unternehmen diese Herstellungskosten für die Erzeugnisse ermittelt werden (MANTHEY, 1995, S. 76). Dieses ist dadurch zu begründen, dass einerseits für die wichtigsten fertigen und unfertigen Erzeugnisse eines landwirtschaftlichen Betriebes steuerliche Vereinfachungen bestehen, die einen Verzicht auf die Ermittlung der Herstellungskosten ermöglichen. Andererseits ist die Ermittlung von Herstellungskosten wegen Kuppelproduktion und vieler Zwischenprodukte schwierig. Beim Feldinventar und bei selbsterzeugten, nicht marktfähigen Vorräten kann steuerlich auf einen Ansatz der Kosten verzichtet werden. Vieh konnte bisher steuerlich weitgehend mit Durchschnittswerten bewertet werden. In den betriebswirtschaftlichen Jahresabschlüssen wird dieses Problem, dass das Vermögen nicht korrekt bewertet ist, nicht behoben, indem die fehlenden Herstellungskosten ermittelt werden, sondern es werden beim Feldinventar die fehlenden Werte und beim Vieh die Durchschnittswerte durch Pauschaldaten ersetzt. Diese Einzelwerte treffen die betriebsindividuellen Verhältnisse nur sehr ungenau, weil die Herstellungskosten von Betrieb zu Betrieb und im Zeitablauf schwanken.

Der Vorwurf einer nicht hinreichenden Anpassung an die sich ändernden Verhältnisse, der in Bezug auf die steuerlichen Durchschnittswerte gemacht wurde, war bereits 1982 auch bei den betriebswirtschaftlichen Werten (Standardherstellungskosten) beanstandet worden. Die Korrektur der Standardherstellungskosten erfolgte 1982/83 durch die *Inkaufnahme eines Bilanzbruchs* im betriebswirtschaftlichen Jahresabschluss. Erst in den 90er Jahren wurden die Wertänderungen gewinnwirksam verbucht. Am 30. Juni 1994 wurde eine Korrektur der Herstellungskosten in erheblichem Umfang notwendig. Wären diese Wertveränderungen nicht gewinnbringend verbucht worden, sondern unter Inkaufnahme eines Bilanzbruches ermittelt worden, so wäre nicht der realisierte Gewinn ausgewiesen worden, sondern der Gewinn, der sich ergeben hätte, wenn sich die Herstellungskosten nicht geändert hätten. Somit wäre der betriebswirtschaftliche Gewinne nicht korrekt ermittelt worden. Nach wiederholten Untersuchungen von Jahresabschlüssen bayerischer Betriebe wurde festgestellt, dass ca. 25 % der Betriebe den Bilanzzusammenhang in den betriebswirtschaftlichen Jahresabschlüssen nicht wahren (KASTNER, 1991, S.787).

Gerade bei der Vermögensbewertung wird deutlich, wie wichtig eine *einheitliche Erfassung* der Betriebsdaten ist und wie unsinnig der Vergleich von unterschiedlich erfassten Betrieben sein kann. Eine Umfrage von WIECZOREK von 1993, bei der 46 Steuerberater in Niedersachsen und Bremen befragt wurden, hat ergeben, dass es zu unterschiedlichen Bewertungsansätzen in der betriebswirtschaftlichen Jahresabschlussanalyse kommt. Der betriebswirtschaftliche Jahresabschluss wird

dabei ausschließlich aus der steuerlichen Buchführung erstellt. Keine der befragten Buchstellen ermittelt einen getrennten betriebswirtschaftlichen Jahresabschluss.

Die *Bodenwerte*, die 66 % des Gesamtvermögens (LANDDATA, 1999) ausmachen, weisen bei der Umfrage folgende Unterschiede auf: 46 % der Steuerberater setzten die zweifache Ertragsmesszahl und 16 % die vierfache Ertragsmesszahl ein. Die restlichen verwenden den Verkehrswert. Die Viehbewertung erfolgte bei 89 % der Steuerberater in der betriebswirtschaftlichen Bilanz mit Standardherstellungskosten. Selbsterzeugte, nicht marktfähige Vorräte werden von 9 % der Steuerberater in dem betriebswirtschaftlichen Jahresabschluss erfasst. Großreparaturen, die betriebswirtschaftlich aktiviert werden müssten, werden im keinen Fall aktiviert. Das gleiche gilt für die Vorratsdüngung. Die Umsatzsteuer für Investitionen unterliegt einer unterschiedlichen Behandlung. Nur 7 % aller Steuerberater aktivieren diese bei pauschalierenden Landwirten.

Wegen der unterschiedlichen Handhabung bei *den Bilanzierungs- und Bewertungsmethoden* der betriebswirtschaftlichen Jahresabschlüsse ist auch die Interpretation und Würdigung unterschiedlich zu behandeln (MANTHEY, 1995, S. 80). Somit besteht ein Bedarf an einem *eigenständigen, einheitlichen, betriebswirtschaftlichen Jahresabschluss*. So wurde u.a. im DLG-Ausschuss für Wirtschaftsberatung und Rechnungswesen ermittelt, wie ein eigenständiger betriebswirtschaftlicher Jahresabschluss aussehen könnte (ARBEITEN DER DLG, 1997, S. 20).

Die Bewertung des Vermögens hat erheblichen Einfluss auf die Bewertung der finanziellen Stabilität des Unternehmens. Insbesondere bei der Ermittlung der Fremdkapitalquote kann eine unterschiedliche Bewertung zu einem anderen Fremdkapitalanteil führen. Das Eigenkapital wird ermittelt, indem vom Vermögen das Fremdkapital subtrahiert wird. Hieraus folgt, je höher der Vermögenswert um so größer das Eigenkapital. Da ein niedriger bewertetes Vermögen vollständig zu Lasten des Eigenkapital geht, steigt die Fremdkapitalquote überproportional an.

Hier wird deutlich, welch großen Einfluss die Vermögensbewertung auf die Jahresabschlussanalyse hat und wodurch eine Bewertung beeinflusst werden kann. Die Erfassung der Daten für den Jahresabschluss hat einen erheblichen Einfluss auf die Auswertung der Jahresabschlussanalyse.

2.4 Aufgabenstellung der Jahresabschlussanalyse

Mit dem Jahresabschluss legen Unternehmen Rechenschaft über den Erfolg ihrer geschäftlichen Tätigkeit und über ihre wirtschaftliche Situation ab, vornehmlich über die Vermögens-, Finanz- und Ertragslage (BURGER, 1995, S.1). Ziel einer Jahresabschlussanalyse ist es, ein *Werturteil über die wirtschaftliche Lage* eines Unternehmens abzugeben. Folgende Informationsbedürfnisse werden von dem Jahresabschluss erwartet:

- Interessenlage der Gläubiger richtet sich hauptsächlich auf die Kreditwürdigkeitsprüfung. Speziell für Banken dient die Bilanzanalyse zur Risikoabschätzung bei der Entscheidung über Kreditanträge
- Interessenlage der Anteilseigner
- Interessenlage der Konkurrenz
- Interessenlage der Kontrollinstanzen
- Interessenlage der Arbeitnehmer

So unterschiedlich die Informationswünsche der verschiedenen Adressaten auch sein mögen, so konzentrieren sich ihre Fragen doch auf zwei Problemstellungen:

- Die Beurteilung der gegenwärtigen *Ertragslage* mit dem Ziel der Ertragsprognose für die Unternehmen
- Die Beurteilung der *finanziellen Stabilität* zur Einschätzung der Fähigkeit des Unternehmens, seinen gegenwärtigen und zukünftigen Zahlungsverpflichtungen nachkommen und mögliches oder notwendiges Wachstum und Anpassungsmaßnahmen an veränderte Markt- und Konjunkturlagen finanzieren zu können.

Durch die Beantwortung dieser Fragen können die Jahresabschlussanalysen einen *Beitrag zur Früherkennung von Fehlentwicklungen* der Unternehmen liefern. Neben der Informationsbereitstellung für externe Adressaten dient die Jahresabschlussanalyse auch als Grundlage zur Informationsgewinnung für das Unternehmen. Hier übernimmt die Jahresabschlussanalyse insbesondere bei kleineren Firmen Kontroll- und Steuerungsfunktionen und wird somit zu einem wichtigen Instrument in der Unternehmensführung.

Folgende Informationen liefert die Jahresabschlussanalyse für den Betriebsleiter (DOWNEY und ERICKSON, 1987, S.134):

1. Zahlungsreserven zu einem bestimmten Stichtag
2. Potential für Rückzahlung von Schulden
3. Trends in den Erträgen und Kosten
4. Trends in der Effizienz der Produktion
5. Kapitalstruktur des Unternehmens und das Potential für Wachstumsschritte
6. Vermögensstruktur und die Kapitalbindungsdauer

Insgesamt muss festgehalten werden, dass Jahresabschlussanalysen selber keine Probleme lösen. Sie sind dafür da, Probleme zu erkennen und Hinweise zu geben, an welchen Stellen die Problemlösung angesetzt werden kann. Die Jahresabschlussanalyse ist also ein *Diagnoseinstrument*.

2.5 Jahresabschlussanalysen als Kontrollsysteme und Finanzanalysen

Die *Jahresabschlussanalyse* ist ein Instrument der Unternehmensführung, denn es ist unübersehbar, dass kaum ein Entscheidungsträger in der Lage ist, ohne Einsatz von Kennzahlen und sonstiger Analyseinstrumente sämtliche, in einem Unternehmen laufend benötigte Informationen zu erstellen, um alle betrieblichen Entscheidungen zu treffen. Es ist nur ein Wunschtraum des Entscheidungsträgers, durch das Auffinden externer und interner Faktoren, Brüche oder Trendwenden in der Entwicklung der wirtschaftlichen Lage eines Unternehmens vorherzusagen. Der Entscheidungsträger muss schon zufrieden sein, wenn es ihm gelingen sollte, sich langsam abzeichnende Veränderungen rechtzeitig festzustellen (LEFFSON, 1984, S.29) und die Möglich- und Wahrscheinlichkeit ihres Eintretens richtig einzuschätzen. Damit ist er zwar vom erklärten Erkenntnisziel der Jahresabschlussanalyse, das in der Erlangung eines den tatsächlichen Verhältnissen entsprechenden Bildes der Vermögens-, Finanz- und Ertragslage liegt, weit entfernt, hat aber dennoch unter realistischer Einschätzung ein zufriedenstellendes Analyseergebnis erreicht.

Für die Informationsgewinnung müssen vorher die Unternehmerziele bekannt sein. Die Aufgabe ist die Leistungserstellung und der Absatz mit dem Ziel, einen wirtschaftlichen Erfolg unter bestimmten Restriktionen herbeizuführen (STEINHAUSER et al., 1992, S.25f.). Dabei kommt der Führung des Unternehmens eine zentrale Bedeutung zu. Sie hat allgemein die Aufgabe, die zukunftsorientierten Ziele des Unternehmens in Soll-Zuständen festzulegen, die Prozesse im Unternehmen zielorientiert zu steuern, im Zeitablauf die tatsächliche Zielerreichung mit den Sollzahlen zu vergleichen und die

Zielabweichung zu analysieren. Das Rechnungswesen hat den Führungsvorgang zu unterstützen.

Deshalb muss die Gliederung und Ausgestaltung des betrieblichen Rechnungswesen von seiner Aufgabe ausgehen, nämlich von der Entscheidungsvorbereitung, der Lenkung, der Dokumentation und der Kontrolle. Das Rechnungswesen als Buchführung ist dabei ein Informationsinstrument mit Informationserfassung, -speicherung, -analyse und -abgabe. Es wurde auch seit jeher als Führungsinstrument gesehen (KOSIOL, 1957 S.61ff.).

2.5.1 Prozess der Finanzkontrolle

Die Finanzkontrolle ist der Prozess der Messung und Kontrolle der Leistungsstärke von Unternehmen über die Zeit. Dies ist ein dynamischer Prozess, in dem ständig neue Informationen, die durch gefällte Entscheidungen entstehen, verarbeitet werden müssen. Diese Kontrolle kann nur einen Rahmen bilden, weil viele Unsicherheitsfaktoren Einflüsse auf die Zukunft nehmen können.

Ein Kontrollprozess ist untergliedert in folgende Schritte (BARRY et al., 2000, S. 92ff.):

1. *Identifizierung der Ziele:* Rentabilität, Stabilität und Liquidität repräsentieren eine Menge von Zielen zur Beurteilung der finanziellen Situation des Betriebes.
2. *Entwicklung von Messzahlen zur Abbildung der Ziele:* Festlegung von Indikatoren und Kennzahlen zur Messung der Zielerreichung.
3. *Festlegung von Normen für die Messzahlen:* Um Messzahlen verwenden zu können, müssen Vergleichsmesszahlen existieren, die von Vergleichsbetrieben stammen oder Zielwerte darstellen, um eine Bewertung der erreichten Zielwerte, zu ermöglichen. Das einfache Maximieren der Kennzahlen ist zu abstrakt. Es können nicht alle Ziele gleichzeitig maximiert werden, da sich bestimmte Ziele negativ beeinflussen. Somit wird ein Ziel maximiert, wobei gleichzeitig für die anderen Zielwerte die Erreichung bestimmter Mindestniveaus erfüllt sein muss. Beispielsweise bedeutet das Erreichen einer höheren Rentabilität meistens gleichzeitig den Anstieg des finanziellen Risikos.
4. *Festlegung von Mindesterreicherung:* Bei Risiko und Unsicherheiten werden selten die Ziele exakt erreicht, deshalb müssen Schwankungsbereiche existieren, in denen keine Korrektur erfolgt.
5. *Entwicklung von Informationssystemen:* Periodische Ermittlung von Kennzahlen, die auf den betriebswirtschaftlichen Buchführungsdaten beruhen, informieren den Entscheidungsträger über die Entwicklung des Unternehmens und können Fehlentwicklungen identifizieren.

Zur Beurteilung der Ziele ist es wichtig, dass diese anhand von aussagekräftigen und händelbaren Feststellungen erfolgt. Es sollte auch beachtet werden, dass Messungen des finanziellen Zustandes nur als Indikatoren oder Auswirkungen ermittelt werden können. Diese sind das Symptom des Problems, nicht aber das Problem selber. Die größte Bedeutung hat hierbei der Richtungswechsel des Indikators.

Eine ständige Kontrolle der Unternehmen ist notwendig, um ein gesundes Wachstum der Unternehmen zu gewährleisten. Zum Vergleich: Ein gesunder Mensch hat eine Körpertemperatur von 37°C , einen entsprechenden Puls, Blutdruck usw. Die Medizin hat eine Vielzahl von Messverfahren zur Ermittlung der Abweichungen von dem Normalzustand entwickelt, um somit Indikatoren zur Ermittlung der gesundheitlichen Probleme zu haben. Ein kranker Körper sendet jeweils entsprechende Signale. Hierdurch können jeweils Diagnosen für die entsprechende Person gestellt werden. Genauso wie der kranke Körper, sendet ein krankes Unternehmen entsprechende Signale aus. Diese Signale können durch Kennzahlen gemessen werden und für die Erstellung einer Diagnose über den finanziellen Zustand des Unternehmens verwendet werden.

2.5.2 Betriebsvergleich als Kontrollinstrument

Für die ökonomische Analyse landwirtschaftlicher Unternehmen gilt, wie für die ökonomischen Analyse aller anderen Unternehmen auch, dass kein allgemeingültiger Algorithmus zur Beurteilung der Unternehmenssituation existiert. KREHL arbeitet allein 25 verschiedene Techniken der Unternehmensanalyse heraus (KREHL, 1985 S.21ff). Daneben belegen überaus zahlreiche Veröffentlichungen zu diesem Problemkreis die Versuche, wenn nicht den sogenannten „Stein der Weisen“ zu finden, so doch zumindest ihm sich zu nähern. RÖSLER verweist allein auf über 100 wissenschaftliche Abhandlungen über empirische Bilanzauswertungen seit 1975 (RÖSLER, 1986, S.33ff.).

Als Kontrollinstrument wird heutzutage in der Landwirtschaft vielfach der *Betriebsvergleich* eingesetzt. Dieser wird im Rahmen der Kontrolle und Problemanalyse durchgeführt. Es sollte hierbei berücksichtigt werden, dass die Auswahl der Kennwerte, die in den Vergleich miteinbezogen werden, sich nach dem Zielsystem des Unternehmens ausrichten. Hier werden in der Praxis sowohl der vertikale wie auch der horizontale Betriebsvergleich eingesetzt. Der Betriebsvergleich ist das klassische Element der Kontrolle als Vorstufe zur Unternehmensanalyse, für die in den meisten Fällen keine spezifische Modelle vorliegen (STEFFEN und BORN, 1987, S.388). Der Betriebsvergleich baut auf Ist-Werte der Vergangenheit bzw. auf den Ist-Werten anderer Betriebe auf.

2.5.3 Auswahl von Kennzahlen für den Betriebsvergleich

Bei der Auswahl von Kennzahlen für die Beurteilung von Rentabilität, Stabilität und Liquidität im Betriebsvergleich ist darauf zu achten, dass diese zur Verfügung gestellt werden können und dass anhand dieser Kennzahl eine Aussagefähigkeit über den jeweiligen Bereich vorliegt. Es können eine Vielzahl von Kennzahlen aus dem Jahresabschluss gebildet werden, aber es werden letztlich nur wenige für eine effektive Analyse benötigt. Die Auswahl der Kennzahlen für die Unternehmensanalyse ist mit vielen Problemen behaftet. In der folgenden Ausführungen soll auf einige hingewiesen werden. Neben der richtigen inhaltlichen Auswahl der Kennzahlen ist auch darauf zu achten, wie diese ermittelt worden sind und aus welcher Datengrundlage sie erstellt worden sind. Bei einer näheren Betrachtung dieser Datengrundlage wird man feststellen müssen, dass zwar Kennzahlen mit einer beliebigen Anzahl an Kommastellen berechnet werden können, aber diese Genauigkeit nur vorgetäuscht ist, weil die Datengrundlage bei einigen Kennzahlen dazu führt, dass nur eine sehr grobe Genauigkeit vorliegt.

Ein typisches Problem für die Bildung von Kennzahlen bei landwirtschaftlichen Unternehmen ist die unterschiedliche Ausstattung mit nicht entlohten Familienarbeitskräften, Eigenkapital und eigenem Land. Der Gewinn, der in der Buchführung ausgewiesen wird, enthält neben dem Unternehmergewinn die Entlohnung für diese nicht entlohten Produktionsfaktoren. Unternehmen mit bisher untypischen landwirtschaftlichen Rechtsformen, wie Aktiengesellschaften, eingetragene Genossenschaften, Gesellschaften mit beschränkter Haftung und Kommanditgesellschaften, werden abweichend davon keine oder nur wenige nicht entlohnte Produktionsfaktoren aufweisen. Dementsprechend muss für eine Vergleichbarkeit der Kennzahlen gesorgt werden (Arbeiten der DLG, 1997, S.1). Die Gewinnkennzahlen müssen bezüglich der Ansätze für die nicht entlohten Produktionsfaktoren korrigiert werden.

Liquidität

Kennzahlen für *Liquidität* sind für die Unternehmensführung wichtig. Ein Unternehmen wird illiquide, wenn es nicht in der Lage ist, seinen kurzfristigen Zahlungsverpflichtungen nachzukommen. Hier ist nicht von Bedeutung, ob das Unternehmen langfristig rentabel gewesen wäre. Deshalb ist das wichtigste Ziel eines jeden Unternehmens, zu jedem Zeitpunkt zahlungsfähig zu sein und unvorhersehbare finanzielle Schwierigkeiten durch finanzielle Reserven zu meistern.

Aus der Buchführung ist es schwierig, Liquiditätskennzahlen zu ermitteln. Es können nur zeitpunktbezogene Liquiditätskennzahlen ermittelt werden. Der Buchführungsstichtag (30.06. für die meisten der landwirtschaftlichen Unternehmen), ist der Tag, an dem die Kennzahlen ermittelt werden. Innerhalb des Jahres kann es zu erheblichen saisonalen Schwankungen kommen. Beispielsweise sind im Ackerbaubetrieb die

Haupteinnahmen im Juli/August und die Ausgaben über das Jahr verteilt. Zur Berechnung der Liquidität während eines Jahres muss zusätzlich eine Kapitalflussberechnung durchgeführt werden.

Stabilität

Um die *finanzielle Stabilität* der Unternehmen beurteilen zu können, müssen Kennzahlen existieren, die beschreiben, ob ein Unternehmen bei unvorhersehbaren Ereignissen in der Lage ist, den Zahlungsverpflichtungen nachzukommen. Aus der Sicht der Kreditgeber ist ein Unternehmen gefährdet, wenn es nicht mehr in der Lage ist, den Kredit zurückzubezahlen. Das bedeutet, dass ein geringer Eigenkapitalanteil ein größeres Risiko für das Kreditgeschäft bedeutet. Deshalb wird sich der Kreditgeber in erster Linie mit der Entwicklung der Kapitalstruktur des Unternehmens beschäftigen.

Rentabilität

Die Rentabilitätskennzahlen besitzen eine zentrale Bedeutung in der Jahresabschlussanalyse und bilden für verschiedene Fragestellungen ein entscheidendes Beurteilungskriterium. Hier sind insbesondere die beiden Kennzahlen Eigenkapitalrentabilität und Gesamtkapitalrentabilität von Bedeutung. Sie spiegeln die Verzinsung des investierten Kapitals oder die erwirtschaftete Kapitalverzinsung wieder. Die Maximierung der Eigenkapitalrentabilität stellt die eigentliche Zielgröße der Unternehmen dar. Die Entwicklung der Eigenkapitalrentabilität ist für die Beurteilung der Unternehmen bezüglich ihrer Fähigkeit, Gewinne zu erzielen, zu investieren und Risiken zu tragen, von beträchtlicher Bedeutung.

Interpretationen von Kennzahlen

Die Erfahrungen der Jahresabschlussanalysten wie auch die theoretischen finanziellen Wirkungszusammenhänge und eine detaillierte Analyse spielen eine entscheidende Rolle bei der Erklärung der Veränderungen von Kennzahlen und somit bei der Identifizierung des verursachenden Problems. Eine Unterscheidung von Zufallsschwankungen und systematischen Veränderungen ist nur schwer abgrenzbar. Bei der Erstellung einer Diagnose müssen die Veränderungen von mehreren wichtigen Kennzahlen, die die Rentabilität, Stabilität und Liquidität repräsentieren, untersucht werden.

Beispielsweise könnte eine Interpretation der Senkung der Umsatzrentabilität sein, dass die Kosten angestiegen sind und ein geringerer Gewinn bei gleichem Umsatz erzielt worden ist. Bei dieser Interpretation der Kennzahl würde daraus gefolgert, dass das Unternehmen seine Kosten nicht mehr im Griff hat. Aber eine Verringerung der Umsatzrentabilität kann auch dadurch zustande kommen, dass der Produktpreis fällt und somit insgesamt sich der Umsatz reduziert hat. Bei der Betrachtung von mehreren

Kennzahlen gleichzeitig kann in diesem Fall die Ursache für den Rückgang der Umsatzrentabilität ermittelt werden.

Wenn sich eine Kennzahl verändert, kann dies, sowohl durch eine Veränderung im Zähler als auch im Nenner, verursacht werden. Beispielsweise bei der Kennzahl "*Liquidität 3. Grades*" können folgende Veränderungen bei Umlaufvermögen und Verbindlichkeiten vorliegen:

- Umlaufvermögen sinkt, kurzfristige Verbindlichkeiten bleiben konstant
- Umlaufvermögen bleibt konstant, kurzfristige Verbindlichkeiten erhöhen sich
- Umlaufvermögen sinkt mehr als die kurzfristigen Verbindlichkeiten
- Umlaufvermögen steigt weniger als die kurzfristigen Verbindlichkeiten
- Umlaufvermögen sinkt, die kurzfristigen Verbindlichkeiten steigen

Hinter diesen Veränderungsmöglichkeiten können also sowohl Umlaufvermögens- wie auch Verbindlichkeitsveränderungen entstehen. Die Umlaufvermögensveränderungen wiederum können sowohl aus Veränderungen der Bewertung als auch des Umfangs des Umlaufvermögens entstehen. Wenn sich das Umlaufvermögen verändert, steht noch nicht fest, welche Teile sich verändert haben und aus welchem Grunde. Auch wird die Frage, ob dieses dauerhaft zu Verlusten führt, nicht beantwortet. Diese Veränderungen der Liquiditätskennzahl können bei einer einjährigen Betrachtung aus zufälligen Schwankungen, aus Veränderungen der Bewertung, aus einer Veränderung der Größe des Betriebes oder aus einem Wechsel in der Produktionsausrichtung resultieren.

Beispielsweise würde bei einer Verringerung der Kennzahl "*Fremdkapitalanteil*" von 50% auf 40% im letzten Jahr - oberflächlich betrachtet - argumentiert, dass dieses Unternehmen einen wichtigen Schritt in Richtung Risikominimierung gemacht hat und jetzt eine höhere finanzielle Sicherheit aufweist. Bei näherer Betrachtung des Jahresabschlusses kann es aber auch sein, dass dieses Unternehmen Vermögensteile, z.B. Boden, verkauft hat, um Zahlungsverpflichtungen zu erfüllen. Es kann mit diesem Geld dann Verbindlichkeiten abtragen. Hierdurch wird sowohl das Vermögen wie auch das Fremdkapital reduziert. Da durch diese Transaktion das Eigenkapital absolut nicht beeinflusst wird, aber das Vermögen reduziert wird, erhöht sich der Eigenkapitalanteil.

2.5.4 Zielkonflikt zwischen Rentabilität und Stabilität

Die Höhe des Fremdkapitalanteils wird von vielen Landwirten, Beratern und Kreditgebern unterschiedlich beurteilt. Einige beurteilen einen niedrigen

Fremdkapitalanteil als erstrebenswert und halten deswegen Reduzierungen des Fremdkapitalanteils als Indikator dafür, dass sich das Unternehmen finanziell stabilisiert. Dies führt aber in der Regel zur einer niedrigeren Rentabilität, weil, solange die Gesamtkapitalrentabilität größer ist als der Zinssatz, eine Erhöhung des Fremdkapitalanteils zur einer Erhöhung der Eigenkapitalrentabilität führt (*Leverageeffekt*) (KÜTING und WEBER, 1994 S. 296).

Beispiel für den Leverageeffekt

Durch den Leverageeffekt wird das Wachstum des Unternehmen mitbeeinflusst. Beispielsweise: Zwei Unternehmen haben die gleiche Summe an Eigenkapital eingesetzt (100.000 DM); Landwirt A hat 100.000 DM für 5 % Zinsen und Landwirt B 50.000 DM für 5 % geliehen. Beide Unternehmen produzieren die gleichen Produkte zu den gleichen Kosten und erzielen somit eine Gesamtkapitalrentabilität von 6 %. Dann wird Landwirt A eine Eigenkapitalrentabilität von 7 % und Landwirt B von 6,5 % erzielen. Hierdurch steht dem Landwirt A auch eine höhere Eigenkapitalveränderung von 500 DM zur Verfügung und besitzt eine höhere Finanzierungskraft für weiteres Wachstum (BARRY et al., 2000, S.159ff.).

Zusammenhang zwischen Wachstum und Leverageeffekt

Die Schlussfolgerung aus dieser Überlegung wäre, dass das Unternehmen für ein schnelles Wachsen eine höhere Verschuldung benötigt. Ein hoher Fremdkapitalanteil führt zu einer höheren Eigenkapitalveränderung. Dieses Eigenkapital steht dem Unternehmen dann für weitere Wachstumsschritte zur Verfügung. Ist aber der Zinssatz höher als die Gesamtkapitalrentabilität, dann tritt der umgekehrte Fall ein, die Eigenkapitalveränderung verringert sich und dem Unternehmen steht weniger Eigenkapital zum Wachsen zur Verfügung.

Durch den Anstieg des Fremdkapitalanteils steigt die Rentabilität und das Wachstum kann hierdurch beschleunigt werden. Zusätzlich können in Zukunft Wachstumsschritte mit einem geringeren Risiko vorgenommen werden, aber gleichzeitig steigt in der Gegenwart das finanzielle Risiko (KASTENS und FEATHERSTONE, 1999, S. 18).

Dies hat folgende Gründe: Durch die hohe Fremdkapitalmenge steigt die Zinsbelastung; bei unvorhersehbarer Verschlechterung der Rentabilität des Kapitals gehen die Gewinne zurück. Gleichzeitig steht aber nur eine geringe Eigenkapitalmenge zur Verfügung, um die entstandenen Verluste abzudecken. Durch die Verringerung des Eigenkapitals und die gleichzeitig schlechtere Kapitalrentabilität wird die Verfügbarkeit von weiteren Krediten zur Überbrückung der finanziellen Verluste stark eingeschränkt. Die finanzielle Stabilität kann bei unvorhersehbaren Ereignissen nicht mehr ausreichen, um allen Zahlungsverpflichtungen nachzukommen. Des weiteren führt eine höhere Instabilität dazu, dass die Variationsbreite des Unternehmenswachstumspotentials sich vergrößert (BARRY et al., 2000, S.168).

Es wäre wünschenswert, wenn der optimale Mix aus Rentabilität und Risiko bestimmt werden könnte. Dies ist leider nicht durchführbar. Die Höhe des Fremdkapitalanteils wird von der Risikobereitschaft des Landwirtes abhängen. Gleichzeitig wird durch den Kreditgeber eine Beschränkung auferlegt, weil dieser mit hoher Sicherheit seinen Kredit zurückerhalten möchte. Eine höhere Rentabilität des Landwirtes interessiert ihn aber nur, wenn sie dazu dient, den Kredit zurückzuzahlen.

2.5.5 Beispiel für ein Verfahren der Finanzkontrolle

Ein landwirtschaftliches Unternehmen ist langfristig gesehen finanziell gesund, wenn sowohl eine ausreichende Stabilität wie auch eine ausreichende Rentabilität vorliegt. Eine ausreichende Stabilitätskennzahl, wie z.B. Fremdkapitalanteil von 10 %, sagt noch nichts darüber aus, ob dieses Unternehmen langfristig diese Stabilität aus eigener Kraft aufrecht erhalten kann. Dies ist nur der Fall, wenn dauerhaft eine ausreichende Rentabilität vorliegt. Hierfür muss die Kapitalrentabilität so hoch sein, dass dauerhaft kein Eigenkapital abgebaut wird. Bei der Klassifikation nach MELICHAR für kommerzielle landwirtschaftliche Unternehmen existiert folgende Aufteilung:

ABB. 1: SCORING-VERFAHREN DER FMHA

Wenn Fremd- kapitalanteil ... ist (in Prozent)	und wenn ROI ... ist (in Prozent)	und wenn die Eigen- kapitalrentabilität ... ist (in Prozent)	dann ist der finanzielle Zustand
Unter 40	Über 0	über 0	Gut
40 bis 70	über 5	über 5	Gut
über 70	über 15	über 15	Gut
Wenn das Unternehmen nicht als gut klassifiziert worden ist, dann			
Unter 10	über -15	über -15	Zufriedenstellend
10 bis 40	über -5	über -5	Zufriedenstellend
40 bis 70	über 0	über 0	Zufriedenstellend
über 70	über 5	über 5	Zufriedenstellend
Wenn das Unternehmen nicht als gut oder zufriedenstellend klassifiziert worden ist, dann			
Unter 10	unter -15	unter -15	Angeschlagen
10 bis 40	über -15	über -15	Angeschlagen
40 bis 70	über -5	über -55	Angeschlagen
über 70	über 0	über 0	Angeschlagen
Wenn keine Klassifizierung für gut, zufriedenstellend oder angeschlagen erfolgt, dann ist der Zustand des Unternehmen "kritisch".			

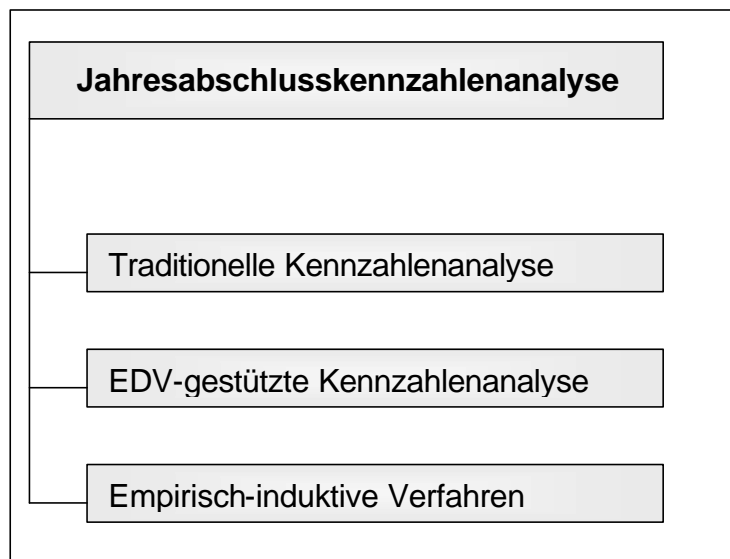
Quelle: Kastens 1999

Hier werden anhand von Kennzahlenkombinationen Aussagen über die finanzielle Gesundheit von landwirtschaftlichen Unternehmen getroffen. Es wurde eine Scoring-Technik verwendet, die sowohl auf Rentabilitäts- wie auf Stabilitätskennzahlen beruht. Anhand von Mindestwerten für die Fremdkapitalquote werden hier Klassifikationen für die Kapitalrentabilitäten vorgenommen. In einem begrenzten Rahmen können günstige Rentabilitätskennzahlen Schwächen in den Stabilitätskennzahlen ausgleichen.

2.6 Ansätze der Jahresabschlusskennzahlenanalyse

Die Jahresabschlussanalyse hat zur Überwachung der finanziellen Situation der Unternehmen im Laufe der Jahre eine große Bedeutung erlangt. Hierdurch erfolgte eine ständige Weiterentwicklung dieser Instrumente, so dass heutzutage nicht nur die traditionelle Kennzahlenanalyse als einziges Instrument zur Jahresabschlussanalyse zur Verfügung steht.

ABB. 2: SYSTEMATIK DER JAHRESKENNZAHLENANALYSE



Quelle: Eigene Darstellung

2.6.1 Traditionelle Kennzahlenanalyse

Die Beurteilung einer Unternehmung erfolgt üblicherweise mit Hilfe von Kennzahlen und Kennzahlensystemen. Bei den Kennzahlensystemen liegt der Gedanke zugrunde, Kennzahlen nicht isoliert sondern in ihrem Wirkungszusammenhang zu betrachten. Auf Kennzahlenkombinationen gestützte Bewertungen von Jahresabschlüssen unterliegen wiederum wegen der frei definierbaren Beurteilungsstufen und Gewichtungen der einzelnen Kennzahlen der Subjektivität des Analysten und genügen somit ebenfalls nicht den gesteckten Anforderungen (REHKUGLER und PODDIG, 1993, S.212).

Bei der Kennzahlenanalyse steht die Informationsverdichtung im Vordergrund, um einen verbesserten Einblick in die wirtschaftliche Lage des Unternehmens zu erhalten. Dabei werden differenzierte Partialanalysen zur Beurteilung von Liquidität, Finanzierung, Erfolg, Investitionstätigkeit usw. durchgeführt. Anschließend sind die

Ergebnisse der Partialanalysen durch den Analytiker zu einem Gesamtbild des Unternehmens zusammenzufassen (KÜTING und WEBER, 1994, S.341).

2.6.2 Kennzahlenvergleich

Als Analysemethoden der Jahresabschlussanalyse werden vorwiegend die Kennzahlenbildung und der *Kennzahlenvergleich* verwendet. Insofern wird Jahresabschlussanalyse häufig auch als Kennzahlenrechnung betrachtet oder sie wird als klassische, traditionelle oder konventionelle Jahresabschlussanalyse bezeichnet (KÜTING und WEBER, 1994, S.16).

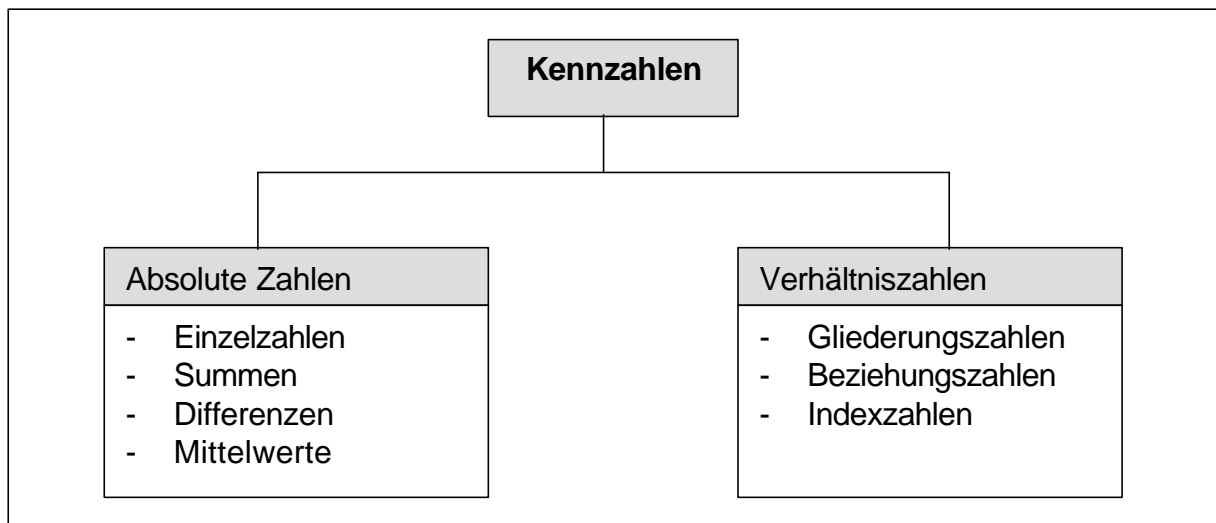
Kennzahlen sind hochverdichtete Maßgrößen, die als Verhältniszahlen oder absolute Zahlen in konzentrierter Form über einen zahlenmäßig, also quantitativ erfassbaren Sachverhalt berichten. Mit ihrer Hilfe sollen die Datenmengen des Jahresabschlusses verdichtet werden zu wenigen, aber aussagekräftigen Größen, um auf relativ einfache Weise komplizierte betriebliche Strukturen und Prozesse abzubilden (REICHMANN, 1993, S.16).

Auf der Grundlage von Kennzahlensystemen als einer systematischen Anordnung von einzelnen Kennzahlen wird versucht, die relevanten betrieblichen Vorgänge und Erscheinungen in ihrer inneren Verbundenheit sowie deren Einbettung in einen komplexen Gesamtzusammenhang darzustellen. Bei einer isolierten Betrachtung einzelner hochverdichteter Kennzahlen können demgegenüber wichtige Detailinformationen verloren gehen (KÜTING und WEBER, 1994, S.17).

Da man Kennzahlen, isoliert betrachtet, nur einen sehr begrenzten Aussagewert zuschreiben kann, schließt sich der Kennzahlenbildung in aller Regel ein Kennzahlenvergleich an. Hierzu verwendete Vergleichsmaßstäbe sind einerseits bestimmte, für sinnvoll erachtete Verhältnisse von Aktiva oder Passiva untereinander oder zwischen Vermögen und Kapital, andererseits auch als sinnvoll unterstellte Verhältnisse von Daten der Gewinn- und Verlustrechnung (KAPPLER, 1974).

2.6.2.1 Kennzahlenarten

Ganz allgemein sind Kennzahlen als ein rechentechnisches Mittel aufzufassen, das bei der Lösung von Entscheidungsproblemen verschiedener Art zur Quantifizierung von Informationen beitragen kann. Die Konstruktion dieser betriebswirtschaftlichen Kennzahlen hängt entscheidend vom jeweiligen Informationsbedarf des Unternehmers ab. Die Kennzahlen können unterteilt werden in absolute und relative Kennzahlen.

ABB. 3: EINTEILUNG VON KENNZAHLEN

Quelle: KÜTING und WEBER, 1994, S.24

Absolute Kennzahlen geben an, aus wievielen Elementen eine näher bezeichnete Menge besteht. Diese Kennzahlen, die auch Grundzahlen genannt werden, können wiederum in Einzelkennzahlen, Summen, Differenzen und Mittelwerte unterteilt werden.

Relative Kennzahlen werden auch Verhältniskennzahlen genannt. Sie entstehen dadurch, dass zwei absolute Kennzahlen in Quotientenform zueinander in Beziehung gesetzt werden. Sie geben also die Relation zweier aufeinander bezogener Größen an. Der Vorteil der Verhältniskennzahl ist die Möglichkeit, die Bedeutung einzelner Größen in Relation zu anderen Sachverhalten aufzuzeigen.

Die Verhältniskennzahlen werden weiter unterteilt in:

- *Gliederungskennzahlen*: Die Größe im Zähler des Quotienten ist ein Bestandteil des Nenners. Sie erscheinen in Form von Prozentzahlen und dienen dazu, Teilmengen der Gesamtmenge zu analysieren.
- *Beziehungskennzahl*: Erfasst ungleichartige Größen, wobei der Teilmengencharakter fehlt. Hier ist zu beachten, dass zwischen Zähler und Nenner ein sachlogischer Zusammenhang besteht.
- *Indexkennzahlen*: Es wird der Anfangs-, Mittel- oder Endwert einer Reihe als Basiswert oder Grundwert gleich 100 gesetzt und die übrigen Werte im Verhältnis dazu umgerechnet.

Kennzahlen sollen Lieferanten von Informationen sein (WAGNER, 1992, S.98). Daher erscheint es sinnvoll, der erweiterten Kennzahlendefinition von LEFFSON zu folgen, der das Postulat aufstellt, "daß eine absolute Zahl nur durch Bezug auf eine andere Zahl zur einer ökonomischen Aussage führt, und daß der durch diesen Bezug gewonnene Quotient erst im Vergleich mit einer anderen Kennzahl informativ wird."

(LEFFSON, 1977, S.176). Ein weiterer Vorteil liegt darin, dass *Verhältniszahlen* keine Rückschlüsse auf die absolute Höhe der Ausgangsdaten erlauben (MÄRZ, 1983, S.12), und somit die Angabe von Verhältniszahlen auch dann möglich ist, wenn die Ursprungsdaten in ihrer absoluten Höhe nicht bekannt gegeben werden dürfen und gleichwohl ein Vergleich angestellt werden soll.

Die in einer Kennzahl verwendeten Größen sollen nach sinnvollen Kriterien konstruiert werden, denn von der jeweiligen sachlogischen Beziehung hängt der Erkenntniswert einer Kennzahl ab. Daher ist in diesem Zusammenhang der "Parallelismus von Sach- und Zahlenlogik" zu beachten. Eine der bedeutendsten Ursachen für Fehler bei der Konstruktion von Kennzahlen ist die suboptimale "Auswahl der Zähler- bzw. Nennergrößen in Bezug auf die Fragestellung" (MÄRZ, 1983, S.80).

Trotz des eingeschränkten Informationsgewinns von absoluten Zahlen steht außer Frage, dass einige von ihnen auch durchaus als Kennzahl bezeichnet werden können (WEBER und KÜTING, 1994, S.24). Beispielsweise die Größen Umsatzerlöse, Cash flow, Bilanzsumme usw. Aus diesen Zahlen lassen sich durchaus bedeutsame betriebswirtschaftliche Erkenntnisse gewinnen.

2.6.2.2 Struktur der Kennzahlen

Bei der buchführungsgestützten Unternehmensanalyse sind die Buchführungsdaten die Basis der Kennzahlenbildung. Aus der Datenmenge müssen im Hinblick auf die Aufgabenstellung aussagefähige Grundzahlen ausgewählt werden und problemorientiert zu Kennzahlen verknüpft werden. Welche und wieviele Kennzahlen zusammengestellt werden, hängt entscheidend von der spezifischen Zielsetzung der Untersuchung ab. Vereinfachend lassen sich zwei Richtungen unterscheiden: Die eine ist bestrebt, die Unternehmenssituation zu beschreiben, die andere versucht darüber hinaus, die Ursachen für diese Situation zu analysieren (GOTTSCHLICH, 1995, S.15).

Bei der Beschreibung der Unternehmenssituation kommt es weniger auf die Vielzahl der betrachteten Kennzahlen als vielmehr auf deren Aussagefähigkeit an. Anhand von Plausibilitätsüberlegungen und Erfahrungswerten werden besonders wichtige Kennzahlen, sogenannte Spitzenkennzahlen, zusammengestellt, mit denen eine erste Charakterisierung der Unternehmenssituation möglich ist. Sollen Unternehmenssituationen tiefergehend analysiert werden, erfordert dies eine bedeutend umfangreichere Anzahl von Kennzahlen (GOTTSCHLICH, 1995, S.16).

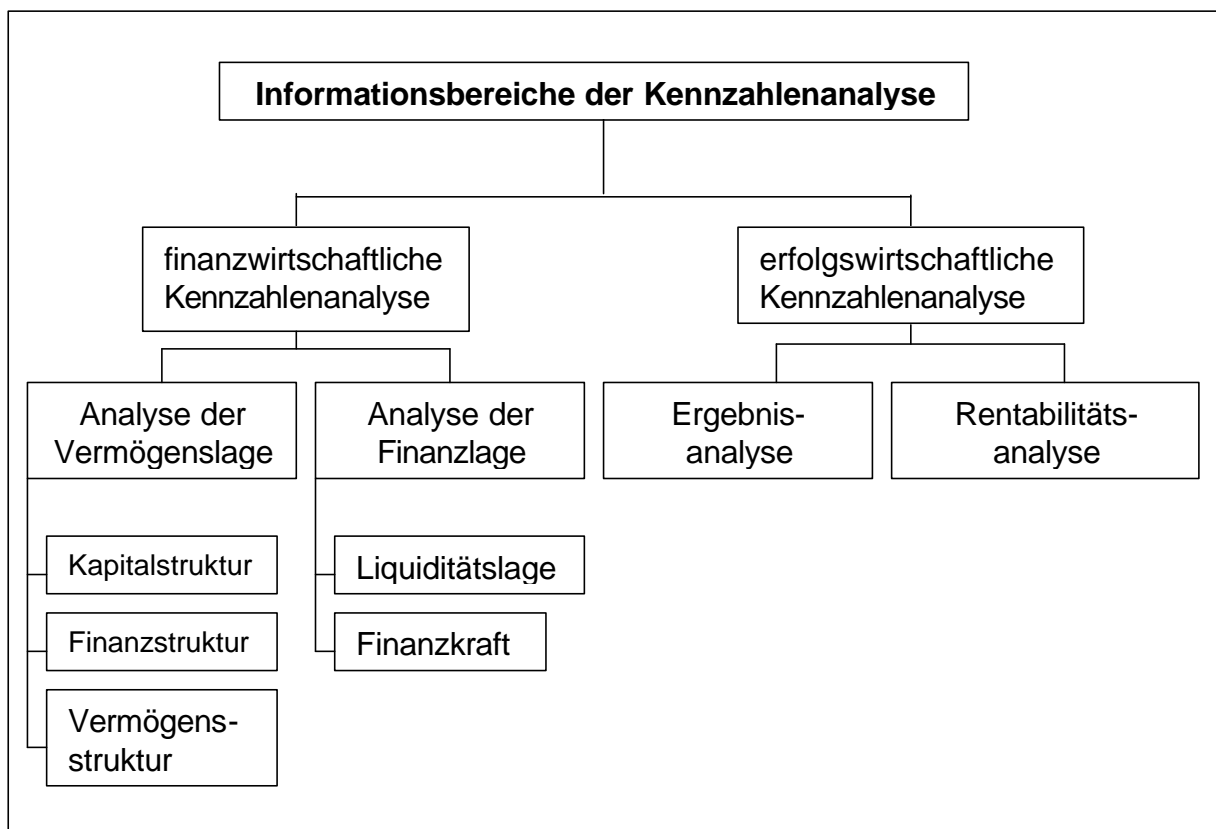
Die Aufgabenstellung bestimmt auch die formale Struktur der Kennzahlen, das heißt die Auswahl der fragegerechten Zahlenart und hier besonders die Wahl der Zähler- und Nennerkomponente. Für die statistische Analyse sollte eine Kennzahl aus möglichst gegenläufigen Zahlen in Zähler und Nenner gebildet werden, da dies zu einer gewissen Hebelwirkung führt und ungünstige Entwicklungen deutlicher sichtbar werden (LEFFSON, 1984, S.183). Eine Hebelwirkung ergibt sich beispielsweise dann, wenn

auftretende Probleme zu einer gegenläufigen Entwicklung von Zähler und Nenner einer Kennzahl führen.

Kennzahlen können grundsätzlich aus allen Positionen des Jahresabschlusses gebildet werden. Für die inhaltliche Interpretation sollte aber darauf geachtet werden, dass die ausgewählten Kennzahlen fachlich interpretiert werden können.

Die Kennzahlenanalyse kann in verschiedene Teilbereiche untergliedert werden, um inhaltliche Zusammenhänge im Unternehmen besser darstellen zu können. In der Abb.4 ist eine Kennzahlenanalyse in verschiedene Informationsbereiche strukturiert dargestellt.

Abb. 4: Informationsbereiche der Kennzahlenanalyse



Quelle: Eigene Darstellung

2.6.2.3 Kennzahlenrechnung als Vergleichsrechnung

Bei einer Kennzahlenanalyse wird zuerst eine statistische bzw. Erstanalyse durchgeführt. Hierbei werden nur Größen des betrachteten Unternehmens in die Auswertung miteinbezogen, die den gleichen Zeitpunkt bzw. Zeitperiode betreffen. Es handelt sich bei der Analyse um eine Zustands- oder Momentaufnahme des wirtschaftlichen Geschehens, bei der der Zeitablauf unberücksichtigt bleibt. Bei der Gewinn- und Verlustrechnung werden nur die Daten einer einzigen Periode in die Analyse einbezogen. Diese statistische Analyse ist der Ausgangspunkt für die Bildung

von Kennzahlen und liefert gewissermaßen das Handwerkzeug für weitergehende analytische Betrachtungen (KÜTING und WEBER, 1994, S.42).

Die statistische Analyse reicht aber nicht aus, um bestimmte Informationen hinreichend auswerten zu können. Denn es fehlt ein Maßstab, an dem die Werte der einzelnen Kennzahlen gemessen werden können. Weil aber die Mehrzahl der Kennzahlen erst durch einen sinnvollen Vergleich mit anderen Kennzahlen Bedeutsamkeit und Aussagekraft erhält, wird die Kennzahlenrechnung in der betrieblichen Praxis grundsätzlich als Vergleichsrechnung ausgestaltet.

Eine Kennzahl wird erst durch die Gegenüberstellung mit normativen Richtwerten oder empirisch abgeleiteten Kenngrößen eine eigene Aussagequalität erlangen. Es ist gerade in diesem Zusammenhang zutreffend festzustellen, dass der einzelne Jahresabschluss ein überaus schlechtes Informationsinstrument zur Vermittlung entscheidungsrelevanter Daten ist (BALLWIESER, 1987, S.57).

Durch die Analyse einer einzelnen Kennzahl kann kein Urteil gebildet werden. Hierdurch ist man allenfalls in der Lage, gewisse auffällige Merkmale, d.h. alles das, was in der Bilanz als untypisch bezeichnet werden muss und sehr auffällig ist, zu erkennen und herauszustellen. Eine Wertung im Sinne von "gut" oder "schlecht" ist in dieser Situation nicht möglich. Dieser Zusammenhang erklärt, warum erst der sich an die statistische Analyse anschließende Vergleich das traditionelle Instrument der Urteilsfindung im Rahmen der Jahresabschlussanalyse ist.

Ein Vergleich liegt vor, wenn gleichartige oder ähnliche Größen, die sich auf unterschiedliche Perioden oder Zeitpunkte beziehen oder bei unterschiedlichen Betrieben gemessen wurden, ins Verhältnis zueinander gesetzt werden.

Jedes Wirtschaftssubjekt möchte aus seiner eigenen Tätigkeit und aus der Erfahrung anderer lernen. Das Wesen des Vergleichs besteht also darin, zu lernen, d.h. zusätzliche Erkenntnisse zu gewinnen (WAGNER, 1992, S.112). Es haben sich schon viele Wissenschaftler mit den Möglichkeiten und Formen betrieblicher Vergleiche auseinandergesetzt. Für den Bereich der Agrarwissenschaften kann auf die Ausführungen von KIMME (1981) verwiesen werden.

Für den allgemeinen Vergleich müssen bestimmte Voraussetzungen erfüllt sein (KÜTING und WEBER, 1994, S.43):

- Das verwendete Datenmaterial muss vor der Bildung von Kennzahlen nach den gleichen Prinzipien bzw. Kriterien aufbereitet werden.
- Die aus der Aufbereitung gewonnenen Grunddaten müssen für die verschiedenen zu betrachtenden Perioden und betrieblichen Sachverhalte inhaltlich vergleichbar gemacht werden. Insbesondere sollte sichergestellt werden, dass die Bewertung der zu analysierenden Größen nach gleichen oder vergleichbaren Grundsätzen vorgenommen wurde.

Der Betriebsvergleich kann nach der Quelle der Vergleichsdaten weiter spezifiziert werden. Bei den Vergleichsdaten kann es sich um kalkulatorisch ermittelte Werte, um eigene Daten der Vorperiode (vertikaler Betriebsvergleich) oder um Daten anderer Unternehmen (horizontaler Betriebsvergleich) handeln (KIMME, 1981, S.12). Nach der Art des Vergleiches lassen sich einzel- und mehrbetriebliche Vergleiche unterscheiden. Die relevanten Daten für den Betriebsvergleich werden aus dem Jahresabschluss entnommen. Die Art und der Umfang der ausgewählten Kennzahlen kann differieren. Die meisten Betriebsvergleiche in der Landwirtschaft benutzen sowohl absolute als auch relative Zahlen.

Es werden folgende Formen von Betriebsvergleichen unterschieden:

- Zeitvergleich (*vertikaler Vergleich*)
- Zwischenbetrieblicher Vergleich (*horizontaler Vergleich*)
- Soll-Ist-Vergleich

Vertikaler Vergleich

Beim *vertikalen Vergleich* werden Größen einander gegenübergestellt, die sich auf unterschiedliche Zeitpunkte bzw. Zeitperioden beziehen, jedoch stets ein und dasselbe Objekt betreffen. Aufgrund eines solchen Vergleichs sollen Vorgänge im Zeitablauf sichtbar und Entwicklungstendenzen verdeutlicht werden (KÜTING und WEBER, 1994, S.43). Mit dem vertikalen Betriebsvergleich werden Veränderungen sichtbar gemacht, wie sie sich im Jahresabschluss niedergeschlagen haben. Allerdings werden die Ursachen dieser Veränderung keinesfalls aufgezeigt (LEFFSON, 1984, S.111). Ein Vorteil dieser Vergleichsrechnung ist aber, dass einmalige Zufälligkeiten leichter erkannt werden.

Horizontaler Betriebsvergleich

Beim *horizontalen Betriebsvergleich* werden Betriebe miteinander verglichen. Hierdurch soll die Stellung des eigenen Betriebes im Vergleich zu anderen Unternehmen abgelesen und Ansatzpunkte zur Beseitigung möglicher Schwachstellen gefunden werden. Für den horizontalen Betriebsvergleich, bei dem der Vergleich von Einzelbetrieben mit Gruppenschneidungen im Vordergrund steht, werden Kennzahlen des gleichen Zeitraumes von einem Analysebetrieb und einem Vergleichsbetrieb bzw. dem Durchschnitt einer Vergleichsbetriebsgruppe gegenübergestellt.

Beim horizontalen Betriebsvergleich sowie beim kombinierten Vertikal- und Horizontalvergleich ist die Aussagefähigkeit des Vergleichs im hohen Maße von der Vergleichsbasis abhängig (STEFFEN und BORN, 1987, S.395). Verglichen werden sollten möglichst Betriebe mit gleichen Standortfaktoren, gleicher Betriebsgröße und ähnlicher Organisationsform und Produktionsrichtung. Je exakter die Vergleichsgruppe dem zu analysierenden Unternehmen in seiner Ausrichtung und Faktorausstattung entspricht, um so informativer und aussagekräftiger ist der Betriebsvergleich (STOLTE, 1976, S.51).

Es wird immer wieder Kritik an dem horizontalen Betriebsvergleich geübt. Der Hauptkritikpunkt ist die eingeschränkte Vergleichbarkeit von zwei Betrieben. Daher rückt diese Form des Vergleiches zugunsten des Vergleiches mit einer Gruppe von Betrieben immer weiter in den Hintergrund. Aber auch hier bleibt der Kritikpunkt der Vergleichbarkeit bestehen. Ein Vergleich ermöglicht durch die Andersartigkeit der Unternehmensverhältnisse erst die Möglichkeit, die Ursachen für die unterschiedliche Ausprägung gleicher Kennzahlen aufzudecken. Würden im Extremfall alle Unterschiede ausgeschaltet, so würden sich auch die Kennzahlen nicht mehr voneinander unterscheiden.

Soll-Ist-Vergleich

Als dritte Vergleichsmethode existiert der *Soll-Ist-Vergleich*. Bei diesem Vergleich werden die vorgefundenen Ist-Werte entweder mit Richtwerten oder Planwerten verglichen. Während Richtwerte in aller Regel auf Erfahrungswerten der Vergangenheit basieren (etwa Durchschnittswerte verschiedener Perioden), ist man bei Plandaten bemüht, zukunftsorientierte Größen einer analytischen Kostenplanung, die im Rahmen einer systematischen Verbrauchsanalyse auf der Grundlage technischer und arbeitswissenschaftlicher Studien erhoben wird, festzulegen.

Beispiel für einen Kennzahlenvergleich

Bei einem Kennzahlenvergleich ist die richtige Interpretation von Kennzahlen und deren Beziehungen untereinander sehr wichtig. Es gibt bestimmte Konstellationen, bei denen die Kennzahlen voneinander abweichen, ohne dass gravierende Unterschiede in den Unternehmen vorliegen. Deshalb muss die Interpretation mit großer Sorgfalt vorgenommen werden. Wie eine abweichende Buchung die Kennzahlen in einem Unternehmen erheblich beeinflussen kann, soll an dem folgenden Beispiel näher erklärt werden:

Tab. 1: Beispiel für die Problematik bei der Kennzahlenanalyse

Informationen für zwei Landwirte		
	Landwirt A	Landwirt B
Liquidität 3. Grades	1,2	2,0
Eigenkapitalanteil	0,67	0,84
Kapitalrentabilität	6,8 %	7,5 %
Bilanz 99/00	in DM	
Umlaufvermögen	75.000	25.000
Anlagevermögen	175.000	175.000
Bilanzsumme	250.000	200.000
Kurzfristige Fremdkapital	62.500	12.500
Langfristiges Fremdkapital	20.000	20.000
Gesamtes Fremdkapital	82.500	32.500
Eigenkapital	167.500	167.500
Bilanzsumme 98/99	240.000	240.000
Eigenkapital 98/99	157.500	157.500
Zinsaufwand	6.600	6.600
Gewinn	40.000	40.000
Gewinn nach Entnahmen für Lebenshaltung	10.000	10.000

Quelle: Eigene Berechnungen

Bei einer Kennzahlenanalyse dieser beiden Unternehmen sprechen die Kennzahlen der *Liquidität*, *Stabilität* und *Kapitalrentabilität* eindeutig für den Landwirten B. Der einzige Unterschied besteht darin, dass der Landwirt B sein Getreide vor dem 30.06. verkauft hat und Landwirt A nach dem 30.06. Landwirt B hat die Einnahmen von 50.000 DM für die Tilgung der kurzfristigen Verbindlichkeiten verwendet.

Diese Transaktion beeinflusst nicht den Gewinn und das Eigenkapital. Sie hat aber einen Effekt auf die Liquidität 3. Grades (Definition: Umlaufkapital/kurzfristiges Fremdkapital) und den Eigenkapitalanteil. Bei dem gleichen Gewinn ohne die

"Entnahmen für Lebenshaltung" und plus "Zinsaufwand" ergibt für Landwirt B eine höhere Kapitalrentabilität. Diese wird für das durchschnittlich eingesetzte Kapital in der vorliegenden Periode ermittelt. Hierfür wird die Bilanzsumme am 01.07. summiert mit der Bilanzsumme am 30.06. und durch zwei dividiert. Deshalb ist das errechnete durchschnittliche Kapital von Landwirt B niedriger als das Kapital von Landwirt A und damit die Kapitalrentabilität höher.

Aus dem Beispiel wird deutlich, dass durch einen einfachen *horizontalen Kennzahlenvergleich* nicht eindeutig das richtige Ergebnis ermittelt werden muss. Eine Kombination aus vertikalen und horizontalen Vergleich führt im allgemeinen zu einem aussagefähigeren Ergebnis.

2.6.2.4 Kennzahlensystem

Um weitere Informationen über die Wechselwirkungen zwischen den Kennzahlen zu erhalten, werden neben den einzelnen Kennzahlen auch ganze Kennzahlensysteme zur Überprüfung der finanziellen Gesundheit der Unternehmen herangezogen.

Ein *Kennzahlensystem* ist die Gesamtheit der auf logisch-deduktivem Wege geordneten Kennzahlen, die betriebswirtschaftlich sinnvolle Aussagen über Unternehmen ermitteln (REICHMANN, 1990, S.16). Kennzahlensysteme versuchen, bisher beziehungslose, nebeneinander stehende Kennzahlen in einem System von gegenseitig abhängigen, einander sich ergänzenden Kennzahlen als eine geordnete Gesamtheit zusammenzufassen (STAEHLE, 1975, S. 317). Hierdurch werden die betriebswirtschaftlichen Zusammenhänge von einzelnen Kennzahlen deutlich gemacht und so die Qualität der Gesamtaussage wesentlich erhöht.

Diese Zusammenhänge können systematischer, mathematischer oder empirischer Natur sein. Bei einem systematischen Ansatz wird von einem, auf ein Oberziel ausgerichteten System von Kennzahlen ausgegangen, das die wesentlichen Entscheidungsbereiche des Unternehmens umfasst und die wechselseitigen Auswirkungen erkennen lässt. Dabei handelt es sich um ein deduktiv aufgebautes Kennzahlensystem, das, wenn es alle Verknüpfungen in quantifizierten Relationen aufzeigt, zu einem mathematisch aufgebauten Kennzahlensystem wird.

Für empirische Systeme gilt, dass jeder Anwender aufgrund von empirischen Überlegungen ein bestimmtes Realsystem zugrunde legt, das er in vereinfachten Zusammenhängen in einem Modell abbildet, um eine Grundlage für die Bildung von wichtigen entscheidungsbezogenen Informationen in Form von Kennzahlen zu bekommen. Wenn von einem empirisch-induktiv gewonnenen Kennzahlensysteminhalt gesprochen wird, liegt ein Modell zugrunde, in das die intersubjektiv nachvollziehbaren Vorstellungen des Systemherstellers eingehen.

Bei einem Kennzahlensystem werden die Kennzahlen durch unterschiedliche betriebswirtschaftliche Zusammenhänge miteinander verknüpft, ohne dass eine quantifizierbare Beziehung zwischen den Elementen hergestellt wird.

Kennzahlensysteme haben die Aufgabe, durch Informationsverdichtung und Zusammenfassung Informationen mit hinreichender Genauigkeit und Aktualität zu liefern. Durch die Reduzierung von komplexen Sachverhalten auf einen einzigen Quotienten bei der Bildung von Verhältniszahlen gehen bei dieser Informationskonzentration wichtige Informationen verloren. Durch den Aufbau von Kennzahlensystemen kann dieser Informationsverlust teilweise oder ganz verhindert werden.

Das älteste und allgemein bekannteste Kennzahlensystem wurde von *DuPont* 1919 entwickelt. Es gilt als Basis- und Grundmodell für weitere Kennzahlensysteme (KÜTING und WEBER, 1994, S.31). Gestaltet ist es als Kennzahlen-Pyramide. Als Spitzenkennzahl wird die Kennzahl "ROA" (Return on Assets) verwendet. Diese Kennzahl setzt sich im Zähler aus dem Gewinn und im Nenner aus dem Gesamtkapital zusammen. Durch die Zerlegung der ROA-Formel werden sowohl die eigenständigen Kennzahlen "Umsatzrentabilität" als auch "Kapitalumschlag" gebildet.

Durch diese Zerlegung der Spitzenkennzahl kann weiter verfolgt werden, wie die ROA-Kennzahl verbessert werden kann. Dies kann einmal durch die Erhöhung der Umsatzrentabilität erfolgen, aber auch durch die Verbesserung des Kapitalumschlags.

Beispiel für ein Kennzahlensystem

An einem Beispiel soll verdeutlicht werden, dass das *Kennzahlensystem von DuPont* eine ausgezeichnete Methode für die Stärken- und Schwächenanalyse von Unternehmen ist. In diesem Beispiel weisen zwar Landwirt A wie auch Landwirt B eine Eigenkapitalrentabilität von 2 % auf. Aber das Zustandekommen dieser Eigenkapitalrentabilität unterscheidet sich voneinander. Diese Unterschiede sind in Tab. 2 anhand von Kennzahlen aufgeführt.

TAB. 2: BEISPIEL EINER DUPONT-KENNZAHLENANALYSE FÜR ZWEI LANDWIRTE

Kennzahlen in Prozent	Landwirt A	Landwirt B
1. Umsatzrentabilität	30	12
2. Kapitalumschlag	20	36
3. Kapitalrentabilität (1 x 2)	6	4,3
4. Zinsen bezogen auf Gesamtkapital	5	3
5. Eigenkapitalquote	50	66
6. Eigenkapitalrentabilität (3-4) / 5	2	2

Quelle: Eigene Berechnung

Beispielsweise hat Landwirt A eine bessere Umsatzrentabilität und Landwirt B eine bessere Kapitalumschlagshäufigkeit. Die Eigenkapitalquote liegt bei Landwirt B höher. Da die Kapitalrentabilität mit 6 % (Landwirt A) und 4,3 % (Landwirt B) unter den zu zahlenden Zinsen von 10 % (Landwirt A) und 9 % (Landwirt B) liegt, verringert sich die Eigenkapitalrentabilität umso stärker, je höher der Fremdkapitalanteil ist. Deshalb weist Landwirt A nur noch eine Eigenkapitalrentabilität in gleicher Höhe wie Landwirt B aus, obwohl die Kapitalrentabilität mit 1,7 % höher ausfiel.

Landwirt A hat eine höhere Umsatzrentabilität. Also liegt der Gewinn pro Umsatz höher bzw. die Kosten pro Umsatzeinheit niedriger als bei Landwirt B. Dieser hat einen höheren Kapitalumschlag, d.h. es wird pro eine Einheit Kapital mehr Umsatz erzielt. Somit existieren für beide Landwirte unterschiedliche Schwachstellen, an denen sie ansetzen müssen, um ihre Eigenkapitalrentabilität zu erhöhen.

Allgemein erstellt und untersucht die klassische Betriebsanalyse Kennzahlen aus der Bilanz, der Gewinn- und Verlustrechnung oder einer Kombination aus beiden Elementen des Jahresabschlusses. Die Untersuchung auf der Basis von Jahresabschlüssen leidet unter der Begrenztheit der zur Verfügung stehenden Daten. Unter anderem werden Daten über Mengen und Preise benötigt, die nicht in befriedigender Form vorliegen; so ist die Aussagekraft der Betriebsanalyse sowie des Betriebsvergleiches oft beschränkt. Sind solche Daten allerdings vorhanden und können in den Vergleich einfließen, so bietet dieses Verfahren eine ausgezeichnete Informations- und Diskussionsgrundlage.

2.6.3 Neuere Ansätze der Jahresabschlussanalyse

Empirisch-induktive Verfahren der Jahresabschlussanalyse sind geprägt durch die Kenntnis, dass logisch-deduktive Verfahren keine befriedigenden Ergebnisse hinsichtlich der Früherkennung der Unternehmensentwicklung liefern. Logisch-deduktive Verfahren unterstellen kausale Zusammenhänge zwischen Informationen des Jahresabschlusses und dem tatsächlichen Zustand eines Unternehmens. Deshalb wird versucht, wenn der kausale Schluss von einer Kennzahlenausprägung auf die tatsächliche Unternehmenssituation nicht möglich ist, die statistischen Zusammenhänge abzuleiten. Diese können zwar keine Begründung für die Unternehmensentwicklung liefern, aber sie können als gute Indikatoren für künftige Unternehmensentwicklungen dienen, wenn die Prämisse der Zeitstabilität für die Zukunft unterstellt wird.

Diese Zielrichtung ist zwar unter Fachleuten umstritten, da sie die Fachkenntnisse der Betriebswirtschaft hinsichtlich der Jahresabschlussanalyse in Frage stellt. Weil aber eine Verbesserung der Klassifizierung von Jahresabschlüssen bisher nur auf diesen Weg möglich war, stellt sie durchaus eine geeignete Entwicklungslinie dar.

Heute beschränkt sich die Jahresabschlussanalyse nicht nur auf die Kennzahlenrechnung. Vielmehr sind im Rahmen der bilanzanalytischen Bemühungen Weiterentwicklungen zu verzeichnen, da es auch Kritik an der Kennzahlenrechnung gibt (KÜTING und WEBER, 1994, S.17).

Gründe für das Ersetzen einer Kennzahlenanalyse durch eine statistische Jahresabschlussanalyse:

- Die klassische Jahresabschlussanalyse hat eine aufgeblähte und ausufernde Kennzahlenproduktion (HAUSSCHILD, 1988, S.115).
- Die Entwicklung von statistischen Verfahren ermöglicht es, auf systematische Weise Unterschiede zwischen zwei Stichproben zu suchen, diese vergleichbar und bewertbar zu machen und schließlich auch Aussagen über die Qualität der Ergebnisse zu treffen (HAUSSCHILD, 1988, S.115).
- Die Einsatzmöglichkeit von Computern in der Jahresabschlussanalyse. Dadurch wird dem Analytiker die Erfassung, Aufbereitung und Auswertung der Datenmenge erleichtert. Allerdings können trotz computergestützter Jahresabschlussanalyse die Grenzen und Probleme nicht oder nur graduell überwunden werden.

Durch diese Gründe haben sich u.a. in den letzten Jahren neuere Methoden der Jahresabschlussanalyse entwickelt. Die bisher bedeutendste ist *die multivariate Diskriminanzanalyse (MDA)*. Ansatzpunkt dieser Methode ist die Frage, inwieweit es signifikante Merkmale gibt, die es erlauben, ein Unternehmen mit Hilfe von mathematisch-statistischen Verfahren als „gut“ oder „schlecht“ im Sinne seiner nachhaltigen Ertragskraft, seiner Zukunftschancen und insbesondere auch seiner finanziellen Stabilität zu qualifizieren.

Zur Beantwortung gleichgelagerter Fragestellungen wie die der MDA erscheint der Einsatz von *Neuronalen Netzen (NN)* besonders geeignet. Sie stellen einen Zweig der *Künstlichen Intelligenz (KI)* dar, deren Anwendungsbereich als lernende Systeme insbesondere bei der Lösung komplexer und schlecht strukturierter Probleme gesehen werden kann (ERXLEBEN, 1992, S.1237ff.).

Die Jahresabschlussanalyse mit Hilfe *empirisch-induktiver Verfahren* setzt an den Kritikpunkten der traditionellen Jahresabschlussanalysen zur Gesamtbeurteilung von Unternehmen an. Ziel der Jahresabschlussanalyse ist, aussagefähigere Informationen über die ökonomische Lage und die Zukunftsaussichten eines Unternehmens zu erhalten, als sie die ursprünglichen Zahlen der Jahresabschlussrechnung liefern (GRÄFER, 1990, S.21). Im Mittelpunkt der Betrachtung stehen insbesondere die finanzielle Stabilität sowie die Ertragskraft des Unternehmens. Dabei bedingen sich beide Erkenntnisziele: Die finanzielle Stabilität ist eine notwendige Voraussetzung für

die Erzielung von Erträgen, und hinreichende Erträge sind zumindest langfristig notwendig, um das finanzielle Gleichgewicht des Unternehmens aufrecht erhalten zu können.

Bei der traditionellen Jahresabschlussanalyse bleiben folgende Fragen zur Gesamtbeurteilung von Unternehmen und so insbesondere zur Früherkennung von Unternehmenskrisen unbeantwortet (KÜTING und WEBER, 1994, S.342):

- Welche der vielen denkbaren Kennzahlen zeigen zuverlässig und frühzeitig negative Unternehmensentwicklungen an?
- Wieviele dieser geeigneten Kennzahlen sind für eine Urteilsbildung zu berücksichtigen?
- Wie können diese Kennzahlen zu einem Gesamtindikator der Unternehmensentwicklung zusammengefasst werden und ab welchem Wert eines solchen Gesamtindikators wird eine mögliche Unternehmensgefährdung angezeigt?

Durch die Verarbeitungsmöglichkeit von großen Datenmengen durch leistungsfähige Computer und die Anwendung moderner statistischer Verfahren wird versucht, die Mängel der traditionellen Jahresabschlussanalyse zu beseitigen. Als statistisches Verfahren kommt dabei die multivariate Diskriminanzanalyse in Frage, die die Kennzahlen im Hinblick auf ihre Eignung zur Insolvenzdiagnose und -prognose bzw. zur Früherkennung von Unternehmenskrisen analysiert und bei multivariaten Verfahren zu einem Gesamtbeurteilungsindikator verknüpft.

2.6.3.1 Diskriminanzanalyse

Als erstes empirisch-induktive Verfahren etablierte sich die *Diskriminanzanalyse*. Maßgebliche Arbeiten für alle späteren Untersuchungen sind insbesondere die Arbeiten von BEAVER (vgl. BEAVER, 1965) und ALTMAN (vgl. ALTMAN, 1967) aus den sechziger Jahren. In Deutschland haben die empirisch-induktiven Analyseverfahren insbesondere in den achtziger Jahren zunehmende theoretische und praktische Bedeutung erhalten.

Folgende Ziele werden versucht, anhand der statistischen Jahresabschlussauswertung zu analysieren:

- Krisenanzeichen sollen frühzeitig erkannt werden.
- Ursachen der unternehmerischen Erfolge und Misserfolge sollen identifiziert und systematisiert werden.
- Unternehmensbeurteilungen sollen auf einer vergleichbaren, objektiven, systematischen, lückenlosen und überschneidungsfreien Basis erfolgen.

Die MDA ist ein *mathematisch-statistischer Ansatz* zur Analyse von Gruppenunterschieden, der es ermöglicht, zwei oder mehr Gruppen hinsichtlich einer oder simultan hinsichtlich mehrerer Merkmalsvariablen zu untersuchen. Mit der MDA lässt sich vor allem untersuchen, mit welchen Merkmalsausprägungen Gruppenunterschiede erklärt werden können.

In der Praxis ist das zweite Anwendungsgebiet der MDA, die *Klassifizierung*, von größerer Bedeutung. Sie ist mit der Frage verbunden: In welche Gruppe ist ein Element, dessen Gruppenzugehörigkeit nicht bekannt ist, aufgrund seiner Merkmalsausprägungen einzuordnen?

Die Voraussetzung für die Durchführung einer MDA ist eine repräsentative Grundgesamtheit von Unternehmen im Rahmen der Jahresabschlussanalyse, die anhand eines vorgegebenen Kriteriums in zwei und mehr Gruppen eingeteilt wird. Das Kriterium, welches in der Praxis bisher am häufigsten angewandt wurde, ist das Auftreten einer Insolvenz in einem bestimmten Jahr oder Zeitraum. Hierbei werden aus den gebildeten Teilmengen zwei Stichproben gezogen: Eine Testgruppe von Unternehmen, die insolvent geworden sind, und eine Kontrollgruppe von solvent gebliebenen Unternehmen. Letztere Gruppe entspricht entweder den insolventen Unternehmen in Größe und Branchenzugehörigkeit, ohne dass auf das Kriterium der ökonomischen Gesundheit geachtet wird (HAUSSCHILDT, 1988, S.18f.), oder sie wird zufällig aus der Gruppe der „gesunden“ Unternehmen gezogen. Aus den Jahresabschlüssen der Test- und Kontrollgruppe werden vorher festgelegte Kennzahlen ermittelt.

Funktionsweise

Die vereinfachte Vorgehensweise der MDA ist folgendermaßen zu beschreiben: Zunächst wird heuristisch oder analytisch überprüft, durch welche Kennzahlen sich die Unternehmen der Test- und Kontrollgruppe voneinander unterscheiden. Sodann wird die Kennzahl ermittelt, die zu einer bestmöglichen Zuordnung der untersuchten Unternehmen in eine der beiden Gruppen führt. Diese Zuordnung erfolgt mit einem für die Kennzahl festgelegten Trennwert (*cut-off-point*). Um das Verfahren praktisch

einzusetzen, muss getestet werden, ob eine Anwendung des gefundenen Trennkriteriums auf bislang noch nicht einbezogene Unternehmen ex post und zukünftig ex ante erfolgreich verläuft (BAETGE, 1980, S.655).

Ziel

Bei der MDA wird versucht, in den historischen Jahresabschlüssen die statistisch signifikanten Zusammenhängen zwischen den einzelnen Kennzahlen und einem zu definierenden Ereignis nachzuweisen und auf künftige Jahresabschlüsse zu übertragen. Dieser Ansatz unterstellt allerdings die zeitliche Invarianz der beobachteten Zusammenhänge. Hierbei wird diesem Verfahren angelastet, dass es keine theoretisch fundierten kausalen Zusammenhänge zwischen Kennzahlen und künftigen Unternehmensentwicklungen aufzeigen kann.

Der Anwender muss sich bewusst sein, dass er in der heutigen Zeit mit leistungsstarken Computern bei der Anwendung von mathematisch-statistischen Jahresabschlussinstrumenten die unbekannt kausalen Zusammenhänge nicht durch immer höhere Rechengeschwindigkeiten ersetzen kann. „Eine Warnung vor solchen Frühwarnsystemen erscheint um so mehr geboten, als der Aberglaube noch immer weit verbreitet erscheint, mittels statistischer Techniken und EDV-gestützter Programme lasse sich Nichtwissen über Finanzierungshypothesen ersetzen und eine Prognose sichern, die quantitative Wahrscheinlichkeiten nutzt.“ (SCHNEIDER, 1990, S.514).

Aufgabe

Dieser Kritik ist entgegenzusetzen, dass diese empirisch-induktiven Verfahren keinen theoretischen Erklärungsanspruch erheben. Ihre Aussagekraft liegt nicht in der Aufdeckung von Ursachen-Wirkungs-Zusammenhängen, sondern vielmehr im *Erkennen typischer Symptome* einer finanziellen Gefährdung (KERLING und PODDIG, 1994, S.434). Sie vergleichen die Situation finanziell gefährdeter beziehungsweise finanziell gesunder Unternehmen aus einer Grundgesamtheit. Wird ein Unternehmen als finanziell gefährdet klassifiziert, so bedeutet das, dass es sich in einer ähnlichen bilanziellen Situation befindet wie der Durchschnitt der finanziell gefährdeten Unternehmen der Grundgesamtheit. Dies setzt die Repräsentativität der Grundgesamtheit voraus. Konkrete Eintrittswahrscheinlichkeiten können und sollen nicht angegeben werden (BAETGE, 1992, S.752).

Unterschiedliche Formen der Diskriminanzanalyse

Die Diskriminanzanalyse kann entweder *univariat*, also mit einer einzigen Kennzahl, oder *multivariat* mit mehreren Kennzahlen erfolgen. Bei der univariaten Diskriminanzanalyse wird die Trennfähigkeit einzelner Kennzahlen untersucht. Für jede in Frage kommende Kennzahl wird ein kritischer Wert, der sogenannte „cut-off-point“, ermittelt, der die beiden Gruppen bestmöglich trennt (HAUSSCHILD, 1988, S.118).

Die Kennzahl, deren cut-off-point die Unternehmen am besten klassifiziert, wird als trennfähigste Kennzahl ausgewählt. Anhand dieser Kennzahl und ihrem cut-off-point werden zukünftig zu klassifizierende Unternehmen einer der beiden Gruppen zugeordnet.

Das *univariate Verfahren* birgt mehrere Schwächen. Durch die Klassifizierung mittels einer Kennzahl wird auf verfügbare Informationen, die in anderen Kennzahlen enthalten sind, bewusst verzichtet. Dies kann zur Folge haben, dass stark überlappende Kennzahlenverteilungen der beiden Klassen hohe Klassifizierungsfehler produzieren. Die einzelnen Kennzahlen stehen in komplizierten Wirkungszusammenhängen zueinander. Dieser Aspekt geht bei der univariaten Diskriminanzanalyse ganz verloren. Verstärker- und Abschwächereffekte zwischen Kennzahlen können nicht erfasst werden.

Um diesen Mängeln Abhilfe zu schaffen, sollten gleichzeitig mehrere Kennzahlen bei der Analyse berücksichtigt werden. Dies führt dazu, dass die Verstärker- und Abschwächereffekte berücksichtigt werden können und alle, als trennfähig erachteten Kennzahlen in eine einzige Klassifizierungsentscheidung einfließen können. Durch die Ausnutzung des Informationsgehaltes mehrerer Kennzahlen wird der Überlappungsbereich der Verteilung beider Klassen und damit der Klassifizierungsfehler verkleinert.

Im Gegensatz zur univariaten Diskriminanzanalyse, in der lediglich ein cut-off-point berechnet wird, ist bei der *multivariaten Variante* zunächst eine lineare Diskriminanzfunktion zu ermitteln, die alle ausgesonderten Kennzahlen gewichtet und additiv verbindet. Erst danach wird ein kritischer cut-off-point bezüglich der Diskriminanzfunktion berechnet. Für ein zu klassifizierendes Unternehmen wird schließlich durch die Diskriminanzfunktion der Diskriminanzwert errechnet und anhand des cut-off-points die Klassifizierung vorgenommen.

"*Multivariate Diskriminanzanalysen* sind Verfahren, die simultan mehrere Kennzahlenverteilungen analysieren und eine Klassifizierungsregel mit mindestens zwei Kennzahlen berechnen" (NIEHAUS, 1987, S.86). Dabei lassen sich folgende Verfahren unterscheiden:

- Verteilungsabhängige oder parametrische Verfahren mit den Unterformen der linearen und der quadratischen Diskriminanzanalyse sowie
- verteilungsfreie oder nichtparametrische multivariate Diskriminanzanalyseverfahren

Anwendungsvoraussetzungen einer MDA

Bisher haben empirische Studien belegt, dass die lineare MDA trotz der nicht erfüllten theoretischen Bedingungen der Normalverteilung und der Varianz-Homogenitäts-Annahme in aller Regel zu besseren Trennergebnissen führt als verteilungsunabhängige oder quadratische Diskriminanzanalyseverfahren. Lineare Diskriminanzanalyse bedeutet, dass die verwendeten - und entsprechend ihrer statistischen Bedeutung gewichteten - Kennzahlen lediglich additiv oder subtraktiv, also linear zu einer Gesamtkennzahl, dem Diskriminanzwert, verbunden werden.

Die erfolgreiche Anwendung der Diskriminanzanalyse ist an Voraussetzungen gebunden, die mit Hilfe verschiedener statistischer Tests und Verfahren im Rahmen der Analyse überprüft werden können. Die Verletzung einer oder mehrerer dieser Bedingungen führt dazu, dass die ermittelte Diskriminanzfunktion nicht optimal trennt. Folgende Voraussetzungen müssen für die lineare MDA existieren (KÜTING und WEBER, 1994, S.354):

- trennfähige Kennzahlen
- unabhängige Kennzahlen
- Varianz-Homogenitäts-Annahme
- Normalverteilung der Kennzahlen

Bei der Diskriminanzanalyse handelt es sich um ein *Klassifizierungsverfahren* und nicht um ein Prognoseverfahren. Dies liegt einmal an den mangelnden theoretischen Voraussetzungen zur Deutung von Häufigkeitszahlen aus der Vergangenheit als quantitative Wahrscheinlichkeitsurteile für die Zukunft (SCHNEIDER, 1985, S.1491) und zum anderen an der implizierten Unterstellung stationärer Bedingungen.

Vorteile einer MDA

Die größer werdende Bedeutung der Diskriminanzanalyse ist auf folgende Vorteile gegenüber einer traditionellen Jahresabschlussanalyse zurückzuführen:

- Es wird ein widerspruchsfreies und intersubjektiv nachprüfbares Gesamturteil über die Vermögens-, Finanz- und Ertragslage des Unternehmens abgegeben, das an einer, wenn auch nicht theoretisch untermauerten, jedoch empirisch getesteten Sollgröße, dem Diskriminanzwert, gemessen wird.
- Zur Abbildung des Informationspotentials des Jahresabschlusses im Hinblick auf eine mögliche Unternehmenskrise werden nicht eine Vielzahl, sondern nur wenige Kennzahlen benötigt, die die entsprechenden Informationsbereiche repräsentieren.

Kritische Bemerkungen

Bei einer MDA handelt es sich um globale Analyse, wobei die Ursachen für eine mögliche Unternehmenskrise nicht hinreichend aufgezeigt werden. Hierfür ist eine Betrachtung disaggregierter Kennzahlen sowie weiterer quantitativer und qualitativer Informationen notwendig. Zusätzlich muss berücksichtigt werden, dass ein Theoriedefizit zur Erklärung von Unternehmenskrisen besteht.

Die betriebswirtschaftlich-theoretische Fundierung eines Diskriminanzwertes ist bisher nicht gelungen. Es steht nur ein empirisch gewonnener Sollwert für Unternehmensentwicklungen zur Verfügung, der nicht mehr als eine Symptombeschreibung der Unternehmensentwicklung ist. Die Diskriminanzanalyse bedeutet im Grunde nichts anderes, als dass ein zusammenfassendes Urteil über das Unternehmen gebildet wird.

Die MDA stellt dabei lediglich die mathematisch-statistische Konsequenz einer qualitativen Analyse mit einer objektiven Gewichtung und Verknüpfung der Kennzahlen dar. Die MDA darf nicht unkritisch angewandt werden. Es ist lediglich eine Voranalyse der Unternehmensentwicklung und bei nicht eindeutigen Unternehmenssituationen ist anschließend eine weitergehende Detailanalyse erforderlich.

Die Diskriminanzanalyse stellt außerdem ein aufwendiges und kompliziertes Verfahren dar. Ohne statistische Kenntnisse sind sowohl die Vielzahl der Voruntersuchungen und Vortests und deren Interpretation als auch die Aufstellung der Diskriminanzfunktion nicht sinnvoll durchführbar.

Der Traum jedes Bilanzanalytikers, „mit Hilfe einer einzigen Kennzahl - die aus mehreren Komponenten zusammengesetzt sein mag - eine Prognose der Zahlungsfähigkeit und Rentabilität der Unternehmung ... liefern zu können.“ (LEFFSON, 1984, S.175), ist auch mit der Entwicklung der MDA nicht erfüllt worden. Trotzdem weisen moderne Jahresabschlussanalyseverfahren wie die Diskriminanzanalyse einen vielversprechenden Weg.

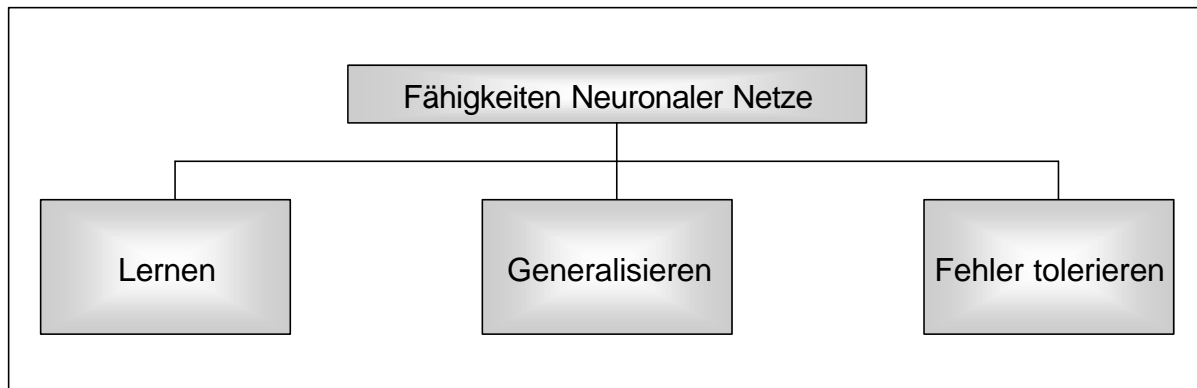
2.6.3.2 Neuronale Netze

Neuronale Netze (NN) bilden wie die MDA ein empirisch-induktives Verfahren, mit dem Jahresabschlüsse analysiert werden können. Dieses Verfahren ist eine alternatives Klassifizierungsinstrument zur MDA.

Die NN sind Verfahren aus der Künstlichen Intelligenz (KI), die versuchen die Arbeitsweise natürlicher NN auf einen Computer zu übertragen (KERLING und PODDIG, 1994, S.435). "Neuronale Netze sind dann einsetzbar, wenn eine unscharfe Informationsverarbeitung vorliegt, die oft als hochdimensionale nichtlineare Abbildung

beschreibbar ist" (KINNEBROCK, 1994, S.11). Ihre Eignung, derartige Probleme zu lösen, ergibt sich daraus, dass NN drei Fähigkeiten aufweisen (Abb. 5):

ABB. 5: FÄHIGKEITEN NEURONALER NETZE



Quelle: Eigene Darstellung

Diese Fähigkeiten ermöglichen den NN grundlegende Zusammenhänge (Muster) einer Grundgesamtheit auf der Basis einer Stichprobe zu lernen und dieses Muster bei den anderen Elementen der Grundgesamtheit wiederzuerkennen, auch wenn das Muster durch spezifische Charakteristika dieser Elemente, dem sogenannten "Rauschen", verdeckt wird.

Wie die empirisch-induktiven Methoden verwenden NN eine große Anzahl von Jahresabschlüssen, um darauf aufbauend ein Klassifizierungs- bzw. Prognosesystem zu entwickeln. Allerdings unterscheiden sich die NN in ihrer Vorgehensweise von der MDA.

Unterschiede der NN zu der MDA

Zuerst müssen die NN mit den Daten der Jahresabschlüsse trainiert werden. In dieser Trainingsphase soll das Netz die Strukturen und Zusammenhänge der Kennzahlen der Jahresabschlüsse erkennen und implizieren. Nach Beendigung der Trainingsphase soll das Netz in der Lage sein, diese erlernten Strukturen in Jahresabschlüssen zu analysierender Unternehmen wiederzuerkennen und darauf aufbauend eine Klassifizierung der Jahresabschlüsse nach erlernten Kriterien vorzunehmen. Voraussetzungen für die Anwendung der NN sind, wie bei der MDA, die zeitliche Invarianz beobachteter Strukturen und die Repräsentativität der verwendeten Daten für die Grundgesamtheit.

Durch die Kritik an der linearen MDA, dass das zu analysierende Datenmaterial die statistischen Voraussetzungen (Normalverteilung, Linearität, Unabhängigkeit der Kennzahlen und Varianz-Homogenität) zumeist nicht erfüllt, versucht man, ein Analyseverfahren zu entwickeln, welches diese Voraussetzungen erfüllt und gleichzeitig bessere Ergebnisse liefert als die MDA. Hierfür eignen sich die NN besonders gut, da sie sich durch Eigenschaften auszeichnen, die sie gerade für diese

Problemstellung besonders interessant erscheinen lassen (KERLING und PODDIG, 1994, S.429):

- Durch ihre Lernfähigkeit eignen sie sich für schlecht strukturierte Problemstellungen, für die keine einschlägigen Theorien verfügbar sind.
- Gegenüber den meisten herkömmlichen multivariaten statistischen Verfahren besitzen sie den Vorteil, Nichtlinearitäten im verfügbaren Datenmaterial nutzen zu können.
- Durch ihre hochgradige Parallelität sind sie in der Lage, gleichzeitig mehrere Kennzahlen, die als geschlossenes Muster betrachtet werden (Verfahren der Mustererkennung), zu verarbeiten. Sie sind somit den multivariaten Analyseverfahren zuzuordnen.
- Für ihre korrekte Anwendung müssen im Vergleich zu vielen statistischen Verfahren weniger strenge Anwendungsvoraussetzungen erfüllt sein.

Da bisher in der Praxis die lineare MDA erfolgreich eingesetzt wurde, und die NN weitere Vorteile ihr gegenüber hat, scheinen sie besonders für die Bearbeitung der vorliegenden Problemstellungen geeignet zu sein. Inwieweit dies in der Praxis umgesetzt ist, ist Gegenstand dieses Beitrages.

2.7 Die Grenzen der Jahresabschlussanalyse

Trotz des erfolgreichen Einsatzes der Jahresabschlussanalyse als Kontrollinstrument zur Überwachung der finanziellen Gesundheit eines Unternehmens eignet sich die Datenbasis der Jahresabschlussanalyse nicht für die unbeschränkte Beantwortung aller finanziellen Fragen. Die Jahresabschlussanalyse kann nicht mehr Informationen aus den Daten herausfiltern als darin enthalten sind.

Durch den Jahresabschluss erhält der Unternehmer zwar viele Informationen und es werden die Zusammenhänge transparenter. Aber es gibt Grenzen bei jeder Analyse, bei denen die verfügbaren Informationen nicht mehr den Informationserfordernissen der Erkenntnisziele entsprechen. Die Informationserfordernisse von Betriebsanalysen liegen vornehmlich in der Vollständigkeit und in der Zukunftsbezogenheit der Daten. Damit gehen die Grenzen der Jahresabschlussanalyse einher (BURGER, 1995. S.6). Wenngleich Kennzahlen ein in der Literatur ausführlich diskutiertes und in der betrieblichen Praxis häufig verwendetes Hilfsmittel zur Unternehmensbeurteilung darstellen, schränken wichtige Faktoren die Aussagefähigkeit der Kennzahlen und damit auch die Möglichkeit der Jahresabschlussanalyse ein.

Die Datenbasis der Jahresabschlussanalyse ist *unvollständig* (HAUSSCHILDT, 1996, S.1). Bilanz und Erfolgsrechnungen geben allenfalls den Rechenschaft, in Geld

ausgedrückten Teil ökonomischen Handels wieder. Im landwirtschaftlichen Bereich sind hier insbesondere die Qualität des Managements und der Mitarbeiter anzusprechen. Weiterhin fehlen genaue Kenntnisse von beispielsweise vorhandenen Kreditreserven und anderen benötigten Daten über das Preis- und Mengengerüst des Betriebes. Insbesondere die letzten Mängel treffen jedoch nur auf den Jahresabschluss im engeren Sinne zu. In den Buchführungsergebnissen sind solche Daten beispielsweise ausgewiesen (WAGNER, 1992, S.96).

Außerdem sind die Daten der Jahresabschlussanalyse *vergangenheitsorientiert*. Bilanzen und Erfolgsrechnungen beziehen sich auf einen vergangenen Stichtag bzw. auf einen abgelaufenen Zeitraum. In der Landwirtschaft ist das in der Regel das landwirtschaftliche Wirtschaftsjahr vom 1.7. bis zum 30.06. des Folgejahres.

Informationen über die künftige Entwicklung der finanziellen Stabilität und der Ertragskraft enthält der Jahresabschluss nicht; bei der Analyse ist man daher gezwungen, von der vergangenen Entwicklung auf die zukünftige zu schließen. Die Daten des Jahresabschlusses sind auch nicht aktuell verfügbar. Der Jahresabschluss liegt erst z.T. einige Monate nach dem Bilanzstichtag vor. Zusätzlich muss berücksichtigt werden, dass die Daten bewertungsabhängig sind. Die Zahlen des Jahresabschlusses sind keine eindeutig definierten Größen. Durch Bilanzierungs-, Bewertungsvorschriften und Wahlrechte werden Vermögenswerte und Verbindlichkeiten oft zu falschen und unrealistischen Werten eingesetzt. Man denke nur an die Möglichkeiten zur Bildung stiller Reserven infolge der Aktivierung auf der Basis der Anschaffungs- und Herstellungskosten, die Bewertung des Bodens usw. (WAGNER, 1992, S.96).

Einer der Hauptgründe für die Buchführung ist die Ermittlung des Einkommens für das Finanzamt. Dementsprechend ist das Hauptziel, die Gewinne soweit wie möglich gering auszuweisen.

Weitere Kritikpunkte der Jahresabschlussanalyse sind, dass bei den Kennzahlen komplizierte Sachverhalte und Zusammenhänge auf eine Nenner- und Zählergröße sowie auf das Ergebnis der Division reduziert wird. Aufgrund der Beschränkung auf diese wenigen Größen besteht zwangsläufig die Gefahr, dass wichtige Erkenntnisse verloren gehen.

Bei dem Vergleich der Kennzahlen aus unterschiedlichen Betriebsgruppen erkennt man schnell Abweichungen der durchschnittlichen Werte einzelner Kennzahlen. Beispielsweise lag 1995/96 der Fremdkapitalanteil bei den Marktfruchtbetrieben bei durchschnittlich 10 % - bei den Futterbaubetrieben bei durchschnittlich 13 % (vgl. LAND-DATA, 1997). Da bei den Futterbaubetrieben ein höheres Anlagevermögen ohne Grund und Boden existiert als bei den Marktfruchtbetrieben, wird dieses Vermögen zu einem größeren prozentualen Anteil mit Fremdkapital finanziert. Auch bei

anderen Kennzahlen, wie der Umsatzrentabilität und andere, treten ähnliche Effekte auf. Deshalb können nur Vergleiche innerhalb der jeweiligen Betriebsgruppen vorgenommen werden. Es existieren sonst Verzerrungen durch die unterschiedlichen Gruppen.

Die Nutzung der Buchführung als Führungsinstrument birgt für den Landwirt somit viele Schwächen (QUIRING, 1996, S.14ff.). Besonders die Analyse des Unternehmens anhand der Kostenstruktur wird durch die Kostenzuordnung im BML-Jahresabschluss erschwert. Deshalb ist die Buchführung für die Kostenberechnungen im Unternehmen nur schlecht zu gebrauchen. Sie wird deshalb nicht von allen Betriebsleitern in der Landwirtschaft genutzt (QUIRING, 1996, S.104).

Für eine weitergehende *Schwachstellenanalyse* ist die Jahresabschlussanalyse nicht ausreichend. Hierfür existieren für das landwirtschaftliche Unternehmen eine Vielzahl von weiteren Rechnungssystemen. U.a. sind die Leistungs-Kosten-Rechnung und Planungsrechnung zu nennen, die neben der Ertrags-Aufwandsrechnung zusätzlich ermittelt werden können. Gerade die Leistungs-Kostenrechnung ermöglicht eine detaillierte Ursachen-Wirkungsbezogene-Analyse (KÖCKLER, 1999, S. 163ff.). Diese zusätzlichen Kostenermittlungen liefern zwar weitere Informationen für eine detaillierte Ursachenforschung bzw. Investitionsplanung, müssen aber zusätzlich ermittelt werden und verursachen somit einen höheren Personal- und Kostenaufwand.

Im landwirtschaftlichen Rechnungswesen haben sich zusätzlich produktionstechnisch orientierte Managementhilfen herausgebildet (MANTHEY, 1995, S.67). Diese sind teilweise nicht miteinander verbunden, sondern werden isoliert geführt. Zu den Managementhilfen gehören beispielsweise Ackerschlagkarteien, Kuhplaner und Sauenplaner. Sie haben teilweise ökonomische Programmteile und werden fast ausschließlich innerbetrieblich geführt.

Gründe für die Jahresabschlussanalyse trotz Kritik

Trotz der angeführten Bedenken und Schwierigkeiten kann jedoch bei der Unternehmensbeurteilung auf die Jahresabschlussanalyse nicht verzichtet werden. Sie stellt eine wichtige Komponente der Einschätzung eines Unternehmens dar (Wagner, 1992, S.96). „Die Bedenken dürfen auch nicht dazu führen, daß man dem Jahresabschluß jeglichen Aussagewert abspricht und ihn daher völlig durch andere Instrumente ersetzen will“ (GRÄFER, 1988, S.52).

Auch bei der Jahresabschlussanalyse gilt das Prinzip der Wirtschaftlichkeit sowie der Wesentlichkeitsgrundsatz der Rechnungslegung. Denn auch im Rahmen der Jahresabschlussanalyse sollten die Kosten der Informationsgewinnung den Informationsnutzen, also den durch die betreffende Information erzielten Ertrag, nicht übersteigen. Das Postulat der Wesentlichkeit ist darüber hinaus auf die Jahresabschlussanalyse an sich gerichtet und verlangt, dass nur solche betrieblichen

Sachverhalte in die Analyse einbezogen werden, die den Einblick in die momentane oder zukünftige Unternehmenslage verbessern bzw. von denen eine mögliche Beeinflussung der Urteilsfindung des Empfängers der Jahresabschlussanalyse erwartet werden darf (SIENERS, 1991, S.18). Die Berücksichtigung des Grundsatzes der Wesentlichkeit in der Jahresabschlussanalyse soll damit gleichzeitig verhindern, dass es zu einer in der Analysepraxis häufig zu beobachtenden Inflation der Kennzahlen kommt.

Als *Kontrollinstrumente* sind die Jahresabschlussanalysen aufgrund geringen zusätzlichen Kosten eine kostengünstige Alternative zur finanziellen Überwachung der Unternehmen.

2.8 Fazit

Die Jahresabschlussanalyse ist ein anerkanntes Verfahren zur Beurteilung der finanziellen Situation eines Unternehmens. Für den erfolgreichen Einsatz dieses Instrumentes ist darauf zu achten, dass die eingehende Datenbasis die Informationen für die Fragestellungen enthalten, die mit der Jahresabschlussanalyse beantwortet werden sollen. Außerdem ist darauf zu achten, dass die verwendeten Daten korrekt erfasst und interpretiert werden. Eine ausreichend korrekte Datenerfassung ist in der Landwirtschaft gewährleistet.

Die traditionelle Jahresabschlussanalyse ist eine *Kennzahlenrechnung*. Durch die Bildung und anschließenden Vergleich von Kennzahlen wird die finanzielle Situation eines Unternehmens beurteilt. Da eine Kennzahl alleine nicht aussagefähig ist, wird diese mit anderen verglichen. Durch einen einheitlichen Jahresabschluss und eine zentrale Verarbeitung der Daten in der Landwirtschaft in wenigen Rechenzentren existieren ausreichende Datenquellen für Kennzahlenvergleiche.

Bei der Bildung und Auswahl von Kennzahlen ist fachliches Vorwissen über die finanziellen Zusammenhänge in einem Unternehmen notwendig. Es müssen Informationen und Wissen über die Liquidität, Stabilität und der Rentabilität vorliegen.

Da über diese Zusammenhänge aber keine vollständigen Theorien vorliegen, haben sich in den letzten Jahren vermehrt die empirisch-induktiven Jahresabschlussanalysen etabliert. Diese Verfahren verzichten auf die Kenntnis der Ursachen-Wirkungs-Zusammenhänge und ermitteln den finanziellen Zustand eines Unternehmens durch das Erkennen von Symptomen. Hierbei handelt es sich um Musterkennungsverfahren. Anhand von Kennzahlenmuster werden die Unternehmen in die jeweiligen Klassen für entsprechende finanzielle Zustände klassifiziert.

In den 70er Jahren etablierten sich zuerst die Diskriminanzanalysen als empirisch-induktive Verfahren. Diese werden in letzten Jahren mehr und mehr von den Neuronalen Netzen verdrängt. Die Fähigkeiten der NN, dass sie lernen, generalisieren

und Fehler tolerieren und gleichzeitig keine statistischen Anwendungs-voraussetzungen erfüllen brauchen, haben dazu geführt, dass diese die Diskriminanzanalysen als empirisch-induktive Verfahren teilweise ersetzt haben.

Obwohl keine vollständige Theorie über die Jahresabschlussanalyse vorliegt, existiert ein Teilwissen über die Zusammenhänge zwischen dem finanziellen Zustand des Unternehmens und den Kennzahlen der Liquidität, Rentabilität und Stabilität.

Dieses unscharfe Vorwissen sollte für eine bessere Klassifizierungsleistung genutzt werden. Die Verarbeitung dieses unscharfen Wissen erfolgt in der weiteren Untersuchung anhand eines Fuzzy Systems. Dieses Instrument eignet sich besonders gut, wenn keine mathematische Beschreibung der Zusammenhänge vorliegt, aber aufgrund längerer Erfahrung ein vages, subjektives Wissen vorliegt.

3 Die Instrumente Neuronale Netze (NN) und Fuzzy Systeme (FS)

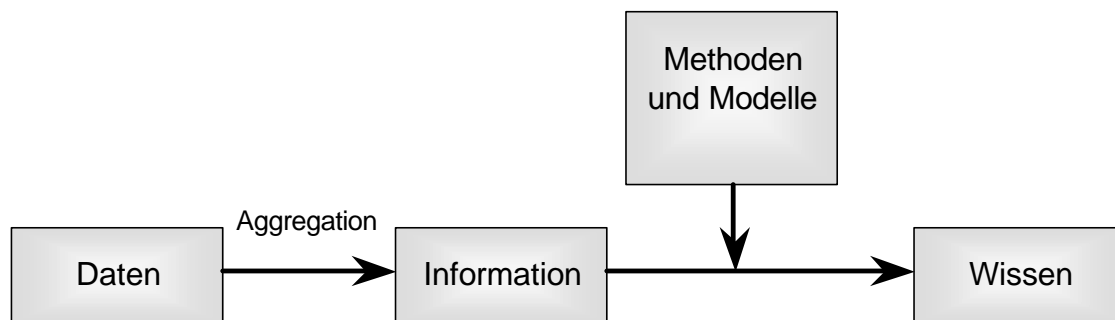
Aufgrund bisheriger Erfolge bei der Anwendung von Neuronalen Netzen in der Jahresabschlussanalyse und den guten Kombinationsmöglichkeiten mit Fuzzy Systemen werden die NN in dieser Untersuchung als Klassifizierungsinstrument für die Diagnose der finanziellen Gesundheit von landwirtschaftlichen Unternehmen im Rahmen einer Jahresabschlussanalyse eingesetzt.

3.1 Theorie und Modellbau

Um die Vorteile und auch Einschränkungen der NN und der FS für die Nutzung der statistischen Jahresabschlussanalyse besser erklären zu können, soll an dieser Stelle näher erläutert werden, um welche Art von Modell es sich hierbei handelt.

In allen, wie auch immer gestalteten Modellen ist Wissen in mehr oder weniger umfangreicher Form eingebunden. Wissen steht in einem engen Zusammenhang von Daten und Informationen. Die Messwerte und Beobachtungen der Umwelt liefern das Datenmaterial, welches durch Aggregation zur Information wird. Unter Aggregation ist sowohl die Verbindung von numerischen Daten mit Maßeinheiten, als auch die Anwendung von statistischen Aggregationstechniken zu verstehen. Wissen erlangt man durch eine Kombination von Informationen mittels geeigneter Verfahren und Methoden. Daher sind Modelle für die Gewinnung von Wissen aus Daten unerlässlich.

ABB. 6: DATENAGGREGATION ZU WISSEN



Quelle: in Anlehnung an KUHLMANN und WAGNER, 1986, S.412

Beschreibung von Modellen

Die Beziehung einer Theorie auf die Wirklichkeit wird in den Wissenschaften mittels der empirischen Modelle einer Theorie ausgedrückt. Der Modellbegriff wird dabei nicht als etwas Eigenständiges betrachtet, sondern ist ein Derivat des formalen Theoriebegriffs. Modelle sind danach abstrakte mengentheoretische Darstellungen von Sätzen einer axiomatischen Theorie, die wiederum konkrete empirische Repräsentationen haben können (FALKENBURG, 1997, S.28).

Der Begriff des Modells wird sehr unterschiedlich und wenig spezifisch benutzt. Die in den Wirtschaftswissenschaften vorherrschende Verwendung ist die im Sinne eines vereinfachenden, aber strukturgleichen bzw. ähnlichen Abbildes eines Ausschnittes der Realität (GUTENBERG, 1973, S.181ff). Der einfachste und präziseste Weg, um zuverlässige Aussagen über das Verhalten eines Systems zu bekommen, ist, das interessierende System selbst unter verschiedenen Bedingungen zu beobachten (BOSSSEL, 1994, S.27). Es stellt sich dann die Frage, ob diese Beobachtung allgemeingültig ist.

Es gibt verschiedene Typen von Modellen. Für die Bearbeitung der vorliegenden Fragestellung sind zwei Modelltypen von Bedeutung:

- Erklärungsmodell
- Prognosemodell

Tab. 3: Zielsetzung und Struktur der beiden Modelle

	Erklärungsmodell	Prognosemodell
Ziel	<i>Erklärung</i> von Zusammenhängen	Prognose von endogenen Größen
Forderung	<i>Strukturelle</i> Übereinstimmung mit der Realität	Verhaltensmäßige Übereinstimmung mit der Realität
Ansatz	Strukturiertes Modell	Black-Box-Ansatz (Verhaltensmodell)

Quelle: BERG und KUHLMANN, 1993, S.9

Im Hinblick auf den Modellzweck kann zwischen zwei Hauptzielrichtungen unterschieden werden: Erklärung von Zusammenhängen und Prognose endogener Variablen. Diese beiden Zielrichtungen schließen sich nicht gegenseitig aus, geben aber jeweils den Hauptgegenstand der Betrachtung an (BERG und KUHLMANN, 1993, S.9).

Bei der Erklärung von Zusammenhängen muss die Modellstruktur sich in weitgehender Übereinstimmung mit der Realität befinden. Für Erklärungsmodelle ist diese Strukturisomorphie ein erforderliches Kriterium. "Besteht das Hauptziel in der Erklärung von Zusammenhängen, so resultiert daraus die Forderung, dass die Modellstruktur sich in weitgehender Übereinstimmung mit der Realität befindet, denn nur dann können die strukturellen Koeffizienten des Modells im Sinne der Erklärung von Kausalzusammenhängen inhaltlich interpretiert werden" (BERG, THOER und STEFFEN, 1988, S.1)

Ist das Hauptziel, Prognosen endogener Größen zu erstellen, dann kann die Forderung nach der Strukturisomorphie in den Hintergrund treten, und es genügt das

Kriterium der Verhaltensisomorphie. Eine so geartete Vorgehensweise wird als "*Black-Box-Ansatz*" bezeichnet. Da die Struktur des Modells nicht zur Erklärung von Kausalzusammenhängen dienen soll, hat ihr Grad der Übereinstimmung mit der Wirklichkeit keine Bedeutung. "Beim *Black-Box-Ansatz* wird versucht, mit Hilfe von formalwissenschaftlichen, mathematisch-statistischen Kenntnissen ein Verhaltensmodell des realen Systems zu konstruieren" (BERG und KUHLMANN, 1993, S.9). Es sollen hierbei keine Kenntnisse über die Ursachen-Wirkungszusammenhänge erlangt werden, sondern das reale System wird als Ganzheit betrachtet.

Festlegung der Komplexität der Modelle

Mit einem Modell sollen Antworten auf *bestimmte Fragen* gefunden werden, d.h. Antworten auf andere Fragen sind nicht gefordert. Der Antwortbereich bestimmt also den Modellzweck. Die Beschränkung des Antwortbereichs und des Modellzwecks ist auch eine Frage der Effizienz. Ein allgemeingültiges Supermodell, das Physiker, u.a. Einstein, gesucht haben, ist bisher nicht erstellbar und wäre für spezielle Probleme ineffizient. Da mit der Komplexität die Fehlermöglichkeiten anwachsen, ist zu erwarten, dass für spezielle Fragen die Zuverlässigkeit und Aussagekraft eines solchen Supermodells zu gering ist. Der Modellzweck ist daher die wichtigste Vorgabe der Modellentwicklung. Je genauer er spezifiziert wird, desto schärfer, präziser und knapper kann die Modellformulierung entwickelt werden. Die präzise Formulierung des Modellzwecks gehört daher an den Anfang der Modellentwicklung (FALKENBURG, 1997, S.38ff.).

Wie die Aufgabenstellung den Modellzweck bestimmt, so bestimmt dieser wiederum Art und Umfang der Modellformulierung. Daraus folgt, dass das gleiche System für unterschiedliche Modellzwecke durch unterschiedliche Modelle abgebildet werden muss. Da die 1 zu 1 Abbildung von System zu Modell im allgemeinen (außer im einfachsten Fall) unmöglich ist, ermöglicht erst die durch den Modellzweck erzwungene Fokussierung auf gewisse Aspekte eine effiziente und knappe Darstellungsweise.

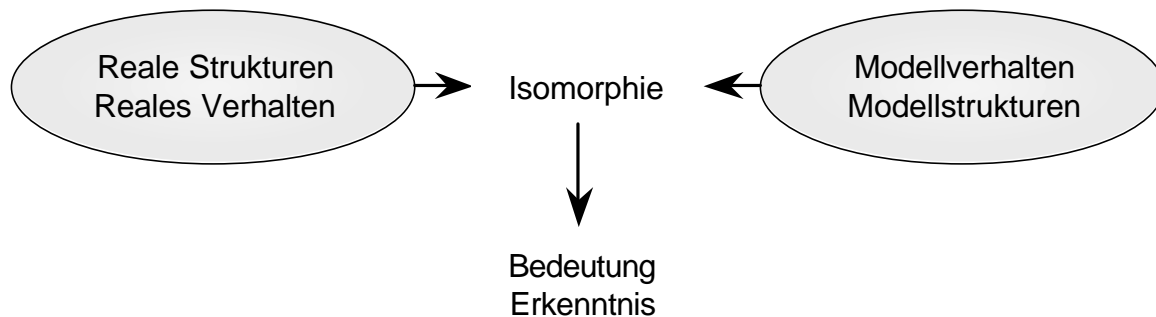
Aus diesen Überlegungen abgeleitet, wird für die vorliegende Untersuchung eine Teilung der Modelle für die Klassifizierung der Jahresabschlüsse in zwei voneinander getrennte Teilgebiete vorgenommen. Es soll das NN und das FS jeweils für den Teil der Modellentwicklung verwendet werden, bei dem die spezifischen Vorteile dieser beiden Modelle existieren. Anschließend sollen beide Modelle sinnvoll miteinander verbunden werden. Es soll die globale Entscheidungsfähigkeit von Fuzzy Methoden mit der Selbstorganisation von NN kombiniert werden.

Neuronale Netze als Selbstorganisierende Systeme

Bei NN handelt es sich um selbstorganisierende Systeme. Hierbei wird ein Modell der empirischen Umgebung des selbstorganisierenden Systems automatisch konstruiert.

Die dabei entstehenden Systemstrukturen sind jedoch zunächst nur rein verfahrenstechnisch interpretierbar.

ABB. 7: ERKENNTNISGEWINNUNG UND MODELLISOMORPHIE



Quelle: WILBERT, 1994

Wenn die Frage nach "Klassifikation und Erkenntnis", "Prognose und Erkenntnis" oder allgemeiner "Funktionsapproximation und Erkenntnis" bei selbstorganisierenden Systemen gestellt wird, dann läuft die Antwort immer über die Explikation des in Abb. 7 dargestellten Zusammenhangs. Bestimmte Modellstrukturen sind autonom durch Verfahren der Selbstorganisation gebildet worden und produzieren ein funktional gewünschtes Verhalten. Es handelt sich hierbei nicht um einen verstehenden Akt der Modellierung real gemessener Strukturen, sondern um einen Akt formaler Approximationen. Dieses formale Modell kann zwecks sachlogischer Interpretationen nur ex post in einen Bezug zur Realität gesetzt werden. Die Etablierung von Bedeutung und die Gewinnung von Erkenntnis über die ex post Entdeckung von Isomorphien mit einem Realsystem oder einem hypothetischen Erklärungsmodell kann nicht mehr auf eine a priori bedeutungstragende Entwicklungstheorie der Modellierung zurückgreifen. Man sieht sich zunächst einmal einem selbstorganisierten "Black-Box-System" gegenüber.

Dieses *Verhaltensmodell*, das das Systemverhalten nachahmt, muss lediglich der Anforderung genügen, gleiches Verhalten zu zeigen. Dabei ist jede Konstruktion, die das Verhalten des Originals nachahmt, akzeptabel. Dieser Ansatz bedeutet, dass das Originalsystem als "*Black Box*" verstanden wird, d.h., dass seine wirkliche Wirkungsstruktur nicht interessiert.

Für die Entwickler der Verhaltensmodelle steht die Anpassung großer Datenreihen aus Beobachtungen mathematischer Zusammenhänge, die nicht in Zusammenhang mit realen Wirkungsstruktur stehen müssen, im Vordergrund. Die Modellentwicklung ist gekennzeichnet durch eine aufwendige Datenbeschaffung, da dieser Modellansatz einen hohen Bedarf an quantitativen Daten aus Verhaltensbeobachtungen hat. Der verhaltensbeschreibende Ansatz der Modellbildung hat seine strikte Anwendungsgültigkeit ausschließlich für jene historischen Bedingungen, für die die Datenreihen vorliegen.

Fuzzy Systeme als Regelbasierte Systeme

Im Gegensatz zu den selbstorganisierenden Systemen, wie die NN, benötigen die FS eine vorgegebene Regelstrategie in Form geeigneter, umgangssprachlicher Regeln. Es handelt sich hierbei um nicht selbstorganisierende Systeme. Im Rahmen der Fuzzy-Regelung wird auf das Erstellen eines mathematischen Modells zwar verzichtet, aber stattdessen wird versucht, die empirischen Beobachtungen mit Hilfe einer Regelstrategie direkt zu beschreiben. Die dabei verwendeten Symbole und Operatoren werden durch das Kalkül der FS in eine mathematisch beschreibbare Form umgesetzt.

Allgemein kann festgehalten werden, dass FS eingesetzt werden, wenn eine direkte analytische Systembeschreibung ungeeignet erscheint, aber aufgrund längerer Erfahrung ein vages subjektives Wissen vorhanden ist. Die Notwendigkeit einer vagen Beschreibung des Systemverhaltens kann sowohl in der Unmöglichkeit genauer quantitativer Messungen als auch in mangelnder Präzision qualitativer, verbaler Aussagen begründet sein.

Eigenschaften der Modelle

Wie generell bei der wissenschaftlichen Theorienbildung gibt es auch bei der Modellbildung das Problem, dass sich die Richtigkeit eines Modells prinzipiell nicht beweisen lässt. Die Tatsache, dass ein Modell in einem bestimmten Anwendungsfall richtige Ergebnisse liefert, ist noch kein Beleg dafür, dass es auch in einem anderen Fall richtig arbeitet. Eine eindeutige Richtigkeit lässt sich nur bestimmen, wenn das Modell falsch ist. Dies gilt insbesondere für NN und FS. Für den Aufbau dieser Modelle existieren keine Algorithmen, sondern sie werden nach dem "*trial and error - Verfahren*" entwickelt und aufgebaut. Somit müssen sie für ein bestimmten Anwendungsfall richtige Ergebnisse liefern, oder sie werden als falsch angenommen.

Für diese Modelle muss belegt werden, dass das Modellsystem das Originalsystem für den Modellzweck vertreten kann und die Gültigkeit im Hinblick auf den Aspekt der empirischen Gültigkeit belegt werden kann (BOSSSEL, 1994, S.36). Hier muss gezeigt werden, dass im Bereich des Modellzwecks die numerischen oder logischen Ergebnisse des Modellsystems den empirischen Ergebnissen des Originals bei gleichen Bedingungen entsprechen.

Modellbildung bedeutet immer Vereinfachung, Zusammenfassung, Weglassen und Abstraktion. Sie ist prinzipiell nicht möglich ohne Auswahl- und Entscheidungsprozesse. Diese Prozesse sind aber nicht frei von subjektiven Einflussgrößen.

Für Systeme mit komplizierten Wechselwirkungen kann die *Universalität* beobachtet werden. Dies bedeutet, dass unter gewissen Voraussetzungen das Verhalten eines

aus sehr vielen interagierenden Elementen zusammengesetzten Systems nicht mehr von Detaileigenschaften seiner Einzelelemente und ihrer Wechselwirkung abhängt, sondern es sich in wenigen Grundeigenschaften präzise vorhersagen lässt. Dies in der Physik bekannte Prinzip gibt Anlass zur Hoffnung, stark vereinfachte Neuronenmodelle durch NN qualitativ korrekt modellieren zu können.

Einen optimalen Gütegrad des Modells zu erzielen ist schwierig. Die in der Realität zu beobachtenden komplexen Phänomene sind durch zu viele Variablen und stochastische Einflussgrößen gekennzeichnet. Hierdurch lässt es sich nicht ausschließen, dass wesentliche Variablen entweder unberücksichtigt bleiben oder in ihren Wechselwirkungen nicht adäquat abgebildet werden.

Die zeitliche Stabilität des Modells kann aufgrund der Dynamik der Einflussparameter nicht gewährleistet werden. Vergangenheit und Zukunft sind prinzipiell nicht strukturgleich. Das Dilemma zwischen vergangenheitsgestützter Prognose und künftiger struktureller Instabilität ist die Ursache des unteilbaren Restrisikos jeder Vorhersage (BRAUN, 1994, S.134).

Unter der zeitlichen Stabilität des Modells ist die Forderung zu verstehen, dass ein in der Vergangenheit beobachtbares Erklärungsmuster des Modells auch in der Zukunft Gültigkeit haben wird. Diese Prämisse wird *Zeitstabilitätshypothese* genannt. Die aus der Vergangenheitsentwicklung entdeckten Strukturen werden unter Zugrundelegung dieser Hypothese analog auf die Zukunft übertragen.

3.2 Die statistische Jahresabschlussanalyse als Modell

Bisher wird die Erstellung von Modellen mit Hilfe von NN und FS als Vorgehensweise des "*trial and errors Verfahrens*" betrachtet. Die fuzzy und neuronale Entwicklungsmethodik hat den Ruf einer Experimentalwissenschaft. Es gibt bis heute keinen Entwicklungsalgorithmus, der pauschal und anwendungsübergreifend die gewünschte Lösung bringt.

Trotzdem sollte vor der Anwendung von Modellen mit NN und FS gut überlegt werden, wie am besten vorzugehen ist. Vor der Modellerstellung von NN sollte das Einbringen von Vorwissen in die Modellvorstellung erfolgen. Folgende Überlegungen sind hierfür notwendig (BRAUN, 1994, S.136ff.):

- Welche Dateninputs bzw. Variablen (Kennzahlen) werden benötigt? Über die Wahl des Dateninputs wird der zugrundegelegte Modellansatz determiniert. Zur Bestimmung des Dateninputs ist zudem noch die Einteilung der Daten in unterschiedliche Teilmengen vorzunehmen.
- Welche Vorkenntnisse über die Zusammenhänge der Variablen (Kennzahlen) liegen vor?
- Welche neuronale Netzarchitektur soll verwendet werden? Hierdurch wird das zugrundeliegende Modellierungskonzept bestimmt.

So wird von vornherein das Vorwissen um die Einflussgrößen und deren Strukturzusammenhänge in das Modell mit aufgenommen.

Die Güte des NN ist grundsätzlich abhängig von der Auswahl der Daten. Dabei ist auf die Verfügbarkeit der Variablen zu achten. Welche Einflussgrößen (Variablen mit kausalem Zusammenhang) und welche Indikatoren (Variablen mit indikativem Gehalt) für das Modell von Bedeutung sind, kann einerseits aus einer Expertenbefragung und andererseits durch die Suche nach Teilen von existierenden Theorien bzw. Theorieansätzen und empirischen Befunden ermittelt werden. Grundsätzlich lassen sich auch qualitative Variablen mit ins Modell aufnehmen. Sie müssen allerdings vorher quantitativ skaliert werden und in ein äquidistantes Zeitraster gebracht werden.

Die im Rahmen der Modellvorstellung in das Modell einfließenden Hypothesen werden im Laufe der Modellerstellung *verifiziert* oder *falsifiziert*. Während der Modellrechnung gilt es, die Hypothesen systematisch anhand der Datenverläufe zu überprüfen. So gelangt man zu einem Endmodell, welches lediglich die hierbei identifizierten, relevanten Variablenbeschreibungen und deren Abhängigkeiten beinhaltet (BRAUN, 1994, S.161).

Gründe für den Einsatz von NN und FS in der Jahresabschlussanalyse

Die statistische Jahresabschlussanalyse ist ein hochkomplexes Gebilde, dessen Zusammenwirken von Variablen weder theoretisch eindeutig erklärbar noch empirisch exakt genug beschreibbar ist. Es existieren eine Vielzahl von Variablen, die in ihrem vollen Umfang nicht alle offensichtlich sind, sich teilweise überlagern und über die Zeit hinweg dynamisch entwickeln, wobei ihre Wechselwirkungen ebenso Veränderungen unterliegen und zudem auch nichtlinear sein können. Ein weiteres Problem ist, dass bei der statistischen Jahresabschlussanalyse zwar viele Kennzahlen zur Verfügung stehen aber nicht alle hierfür notwendigen.

Es liegt nahe, für die statistische Jahresabschlussanalyse Methoden einzusetzen, welche vor dem Hintergrund eines komplexen, sich in einem steten Wandel befindlichen Szenarios, eine systematische *Ursachen-Wirkungs-Analyse* durchführen

können. Eine effiziente Klassifizierung der Unternehmensentwicklung auf der Grundlage von Jahresabschlüssen impliziert die Notwendigkeit, eine hohe Anzahl an Variablen auf lineare und nichtlineare Abhängigkeit hin zu untersuchen, wobei auch der Dynamik der Wechselwirkungen Rechnung getragen wird.

Bei der Prognose einer Unternehmensentwicklung anhand von Kennzahlen aus der Vergangenheit aufgrund eines Erklärungsmodells würde voraussetzen, dass eine Theorie der Jahresabschlussanalyse vorliegt. Dadurch könnte man anhand von *Ursachen-Wirkungs-Zusammenhängen* die Realität in einem Erklärungsmodell abbilden. So müssten Variablen festgelegt und mathematisch beschrieben werden.

Im statistischen Sinne bedeutet die Vorgabe eines Modells, dass a priori sowohl eine Festlegung auf bestimmte Variablen und deren Vorverarbeitung als auch auf deren mathematischen Beziehungen und ihren Abhängigkeiten erfolgen muss. Hierbei werden konkrete Funktionstypen unterstellt. Da bei der Jahresabschlussanalyse keine einschlägigen Theorien vorliegen und so auch keine Modellvorgabe im statistischen Sinne, d.h. Festlegung auf bestimmte Variablen und mathematische Beschreibung ihrer Abhängigkeiten, vorgenommen werden kann, ist die Verwendung eines bestimmten Modells vorher genau zu überdenken.

Wie von FALKENBURG (vgl. Kapitel 3.1) gefordert ist, gehört an den Anfang einer Modellentwicklung die Formulierung des Modellzwecks. Dieser bestimmt wiederum die Art und den Umfang des Modells. Bei einer statistischen Jahresabschlussanalyse sollen die Kennzahlen zu einem Gesamtindikator für die Unternehmensentwicklung zusammengefasst werden. In erster Linie ist die Bildung dieses Indikators von Bedeutung. Die Erklärung, wie dieser zustande kommt, ist in diesem Fall nur sekundär relevant. Deshalb eignen sich NN als "Black-Box-Ansatz" besonders für die statistische Jahresabschlussanalyse.

Da aber gleichzeitig kein empirisch erfassbarer Indikator (eindeutiges Ereignis) vorliegt, nach dem klassifiziert werden kann, und dieser nur über Kennzahlen abgeleitet werden kann, wird ein zweites, zusätzliches Modell aufgebaut. Der Gesamtindikator liegt nicht empirisch vor, sondern wird über definierte Kennzahlen festgelegt. Hierdurch ist Wissen über die verwendeten Kennzahlen und deren Wechselwirkungen bekannt. Der Gesamtindikator wird nicht anhand der Verwendung eines "Black Box-Ansatzes" ermittelt, sondern anhand eines FS.

Auch wenn bei den NN eine hohe Modellfreiheit vorliegt, ist bei ihnen eine bestimmte Modellvorstellung notwendig. Aber es kann auf eine genaue parametrisierte Beschreibung der zugrundeliegenden Funktion verzichtet werden. Das Netzwerk versucht durch Lernen die den Daten zugrundeliegende Funktion zu finden. Die hierbei stattfindende Verknüpfung von Linearkombinationen sigmoider Funktionen eignet sich zur Approximation beliebiger komplexer Funktionen. Ein NN besitzt somit die Fähigkeit,

relevante Strukturzusammenhänge in den Daten zu erkennen und selbständig zu gewichten.

Notwendige Modellvorgaben

"Modellvorstellung im neuronalen Sinn bedeutet folglich im wesentlichen die Festlegung auf eine möglichst repräsentative Teilmenge an Variablen und deren möglichst effiziente Aufbereitung" (BRAUN, 1994, S.136ff.). Der Datenauswahl kommt eine große Bedeutung zu, da sie mit zu der inneren Konnektivität des Netzwerkes beiträgt: Der Umfang des Datensatzes sollte genügend groß und hinsichtlich der Klassifizierung repräsentativ sein, um die Struktur der Daten charakterisieren zu können.

Für den Modellaufbau ist die zwingende Festlegung von Variablen bzw. Kennzahlen bei der Jahresabschlussanalyse nicht erforderlich, aber aufgrund der komplexen Wirkungszusammenhänge und großen Anzahl von Kennzahlen ist es notwendig, sich von vornherein auf bestimmte wichtige und einflussreiche Kennzahlen festzulegen.

Neben dem fehlenden theoretischen Wissen erschweren die materiellen und strukturellen Grenzen des vorliegenden empirischen Materials (Jahresabschlüsse) die Entwicklung eines NN:

1. Materielle Grenzen:

- Partielle Abbildungen der Lage eines Unternehmens: Die Informationen bilden die Lage des Unternehmens materiell nur begrenzt ab.
- Vergangenheitsorientierung: Die Daten sind vergangenheitsbezogen, so dass bei ihrer Analyse unterstellt wird, dass sich die Strukturen der ex post Unternehmen auf künftige Unternehmen übertragen lassen.

2. Strukturelle Grenzen:

- Unvollständige und unscharfe Daten: Nicht für jedes Unternehmen liegt das gesamte Datenmaterial vor. Vielmehr ist das Datenmaterial zum Teil unvollständig oder u.U. fehlerhaft erfasst worden.

Die *materiellen Grenzen* des Datenmaterials, dass die Daten nur einen partiellen Einblick in die wirtschaftliche Lage des Unternehmens ermöglichen und überwiegend vergangenheitsorientiert sind, kann das Analyseinstrument NN nicht beheben. Die materiellen Grenzen der Daten bilden auch für die Leistung des NN einen gegebenen Rahmen.

Eigenschaften von Neuronalen Netzen

Die *strukturellen Grenzen* können aber durch das NN abgefedert werden. Das erlernte Wissen speichert das NN nicht lokal an einer bestimmten Stelle sondern über das gesamte Netz verteilt ab (***verteilte Wissensrepräsentation***). Aufgrund der verteilten Wissensrepräsentation gelangt das NN selbst dann noch zu einem plausiblen Ergebnis, wenn einzelne Merkmale eines Unternehmens nicht vorhanden sind. Da ein NN Eingangsdaten als Muster in der Netzstruktur abbildet, werden unvollständige Datensätze mit Standardwerten aufgefüllt und schließlich ein Ergebnis ermittelt (ZELL, 1994, S.23). Indes ist nicht jedes trainierte NN fehlertolerant. Vielmehr ist schon bei der Entwicklung des NN zu berücksichtigen, ob ein fehlertoleranter Einsatz des NN notwendig ist. Ein fehlertolerant entwickeltes NN ist auch gegen verrauschte und fehlende Daten robust (***Robustheit gegen verrauschte und gegen fehlende Daten***). Als verrauschte Daten gelten die, bei denen die erfassten Ausprägungen eines Merkmals um ihren tatsächlichen Wert streuen und diesen folglich nicht exakt wiedergeben.


3.3 Die Mustererkennung

Die heutigen NN sind zum Standardinstrument der Behandlung von Mustererkennungen geworden. Aus diesem Grund wird hier kurz die grundsätzliche Vorgehensweise der Mustererkennung dargestellt.

Die Definition der Mustererkennung von MERTENS lautet: "Die Mustererkennung befasst sich mit Maßnahmen zur automatischen Verarbeitung von Mustern. Dazu gehören die Einordnung von Mustern in Musterklassen, die Analyse von Mustern und die hierzu erforderlichen vorbereitenden Operationen" (MERTENS, 1977, S.779). Es kann festgestellt werden, dass die Mustererkennung die Suche nach der Struktur in den Daten ist. "In den Wirtschaftswissenschaften dürften vor allem die abstrakten Muster Bedeutung haben, bei denen ganz unterschiedliche Merkmale zur Beschreibung herangezogen werden" (MERTENS, 1977, S.779).

Die folgende Abbildung 8 zeigt das Schema eines einfachen Mustererkennungsprozesses:

ABB. 8: MUSTERERKENNUNGSPROZESS



Quelle: MERTENS, 1977

Für das eigentliche Mustererkennungsproblem gilt es, die wirklich wichtigen Merkmale herauszufinden. Diese sind in der Regel zahlenmäßig geringer als es das zugrundeliegende Datenmaterial erlaubt. Unwichtige Merkmale, die nicht zu der Lösung des Erkennungsproblems verwendet werden, können die Muster stören. Diese Variablen verwaschen das zu untersuchende Signal.

Von einer *Klassifizierung* spricht man, wenn ein Musterraum X (Eingaberaum) in den Klassen X_1, \dots, X_n zerfällt. Bei der Formulierung des Entscheidungsproblems geht man davon aus, dass es eine Grenze zwischen den X_i gibt, die approximiert werden kann. Indem die Beschreibung dieser Grenze gefunden wird, wird das Problem gelöst. Für ein gegebenes $x \in X$ kann dann gesagt werden, zu welchem Teilraum X_i dieses Element dann gehört.

Entscheidend für den Klassenbildungsprozess ist die Festlegung von geeigneten Eigenschaften für die einzelnen Klassen. Durch eine Vielzahl von Daten lernt das System das Muster.

Ein einfaches Muster wird somit in folgenden Schritten klassifiziert (HENO, 1983, S.169ff.):

- In einer Vorverarbeitung werden Störeinflüsse in den Mustern reduziert und die Muster in eine für die weitere Verarbeitung geeignete Form gebracht.
- Merkmalsausprägungen sind zu extrahieren und zu messen. Aus wirtschaftlichen Gründen ist es notwendig, die Merkmale mit der größten Diskriminanzfähigkeit auszuwählen.
- Aufgrund von gespeicherten Klassencharakteristika ist das Muster einer bestimmten Klasse zuzuordnen, deren Klassenname auszugeben ist.

Weil dem System die Information "Klasse" zusammen mit dem Muster eingegeben wird, handelt es sich hierbei um überwachtes Lernen. Im Gegensatz dazu ist beim unüberwachten Lernen dem System die Klassenzugehörigkeit der Muster in der Stichprobe nicht bekannt. Das System muss die Klassencharakteristika selbst aus den Merkmalen gewinnen.

Das Wesen der Mustererkennung ist, diejenigen Merkmale von bereits klassifizierten oder von bisher noch nicht klassifizierten Objekten oder Sachverhalten ausfindig zu machen, die den Mitgliedern einer Klasse gemeinsam sind und in denen sich die Mitglieder verschiedener Klassen deutlich voneinander unterscheiden.

3.4 Neuronale Netze (NN)

3.4.1 Hintergrund

Das Neuronale Netz ist ein empirisch-induktives Verfahren. Da für die Entwicklung der NN kein mathematisches Modell notwendig ist, stellt sich die Frage, wie die NN zu anderen Modellen eingeordnet werden können.

Die Begabung des Menschen, seine Umwelt ergründen und erkennen zu können, beruht unter anderem auf der Fähigkeit, Informationen und Informationseinheiten zueinander in Relation setzen zu können. Dadurch entstehen Abbildungen, Zuordnungen und Funktionen. Diese Zuordnungen beschreiben modellhaft die Erscheinungen der naturwissenschaftlichen Welt.

Die Abbildungen werden in drei verschiedene Grundtypen eingeteilt:

1. „*berechenbar*“: Für die Zuordnungen dieser Art existiert ein abbrechender Algorithmus, der die Ermittlung der Funktionswerte erlaubt.
2. „*intuitiv*“: Hierzu gehören bestimmte Prognosen, Diagnosen und Klassifikationen. Es handelt sich hierbei um eine unscharfe Informationsverarbeitung.
3. „*chaotisch*“: Diese Zuordnungen sind weder berechenbar noch intuitiv erfassbar. Zuordnungen dieser Art sind Untersuchungsobjekte der Chaostheorie.

Zuordnungen der ersten Gruppe sind wegen ihrer Berechenbarkeit problemlos abzubilden. Die Abbildungen der Gruppe drei hingegen wird nach dem heutigen Wissen in keiner Art und Weise erfassbar sein. Die Zuordnungen der Gruppe zwei sind weder rein chaotisch noch mit einem Algorithmus berechenbar. Es handelt sich hierbei meistens um hochdimensionale, nichtlineare Zuordnungen, wobei die Zuordnungen selbst noch unscharf sein können. Es gibt Fälle, in denen solche Abbildungen intuitiv erfassbar sind. In diesen Fällen wurde durch langjährige Erfahrungen die Zuordnung möglich. So stellt sich die Frage, ob Systeme existieren, die eine Zuordnung erlernen können.

Hierfür liefert das Gehirn der Säugetiere mit seinem neuronalen und synaptischen Aufbau die Vorlage. In der Vergangenheit entstand aus dieser Vorlage die Theorie der Neuronalen Netze (NN) (KINNEBROCK, 1994, S.10).

Nervensysteme sind informationsverarbeitende Systeme, die aus einer großen Anzahl einfacher Einheiten (Zellen, Neuronen) bestehen, die sich Informationen in Form der Aktivierung der Zellen über gerichtete Verbindungen zusenden (ZELL, 1994, S.23).

Die NN sind abgeleitet von den Gehirnen der Säugetiere, bei denen die Informationsverarbeitung durch sehr viele Nervenzellen stattfindet. Im Verhältnis zum Gesamtsystem sind diese sehr einfach aufgebaut. Sie leiten die Erregungen über Nervenfasern an andere Nervenfasern weiter. Grundsätzlich bestehen NN aus Verarbeitungseinheiten, den sogenannten "*Neuronen*", die miteinander verbunden sind und parallel arbeiten. Die Neuronen erhalten Muster als Eingangssignale, welche sie verarbeiten, und als Ausgangssignale an verbundene Neuronen weiterleiten. So gesehen können NN als computergestützte Informationsverarbeitungssysteme, basierend auf der Simulation der Informationsverarbeitung innerhalb lebender Nervensysteme, beschrieben werden. Diese führen kontextabhängige Interpretationen und Abstraktionen von Daten durch.

Bei den NN handelt es sich um massiv parallele, lernfähige Systeme, die auch für sich genommen als parallele Algorithmen interessant sind. Diese Algorithmen sind in Form von Programmen, Netzwerksimulatoren oder auch in Form spezieller neuronaler Hardware in vielen Anwendungsgebieten einsetzbar.

Die NN werden von Forschern mit unterschiedlichen fachlichen Ausrichtungen benutzt. Das Forschungsgebiet „*Neuronale Netze*“ berührt eine Reihe von Disziplinen, in denen unter verschiedenen Gesichtspunkten mit dieser Technologie Forschungsarbeiten durchgeführt werden.

In den biologische- bzw. medizinerorientierten Disziplinen (Biologie, insbesondere Neurobiologie, Medizin und Psychologie, insbesondere Neurophysiologie und Neuropsychologie) werden konnektionistische Ansätze zur Modellierung von natürlichen Systemen betrachtet. Im Bereich der Elektronik sind Probleme der hardwaremäßigen Realisierung neuronaler Architekturen von großer Bedeutung. Weiterhin werden NN zur Steuerung von Robotern oder bei der Auswertung von Sensordaten verwendet (SCHERER, 1997, S.16).

In den Bereichen der Mathematik, aber insbesondere der Informatik, beschäftigen sich viele Ansätze mit den theoretischen und praktischen Grundlagen der NN. Neben sehr formalen Untersuchungen zu deren Eigenschaften werden Untersuchungen zu neuen Lernalgorithmen, Konvergenzanalysen und performanten Realisierungen vorgenommen.

Es gibt neben den Anwendungen der NN in den naturwissenschaftlichen Disziplinen auch sehr viele Anwendungen in betriebs- und volkswirtschaftlichen Gebieten (Ökonomie und Ökonometrie).

3.4.2 Anwendungsfelder Neuronaler Netze in der Betriebswirtschaft

NN werden bisher mit großem Erfolg in drei verschiedenen Aufgabenfeldern der Betriebswirtschaft eingesetzt, die auf der Mustererkennung basieren (HAWLEY et al., 1996, S.34):

- Klassifizierung
- Cluster
- Assoziiertes Erinnern (associative memory)

Es wird gegenwärtig an vielen Projekten gearbeitet, die NN-Technologien verwenden. In der Finanzwirtschaft haben sich NN bisher als Kreditwürdigkeitsprüfungs-, Aktien- und Währungsprognoseinstrumente bewährt. *HALBERT WHITE* von der Californischen Universität in San Diego hatte frühzeitig damit begonnen, ein NN mit Tagesdaten von Aktienwerten zu trainieren, um somit Schwankungen im Aktienmarkt vorherzusagen. Es ist ihm aber nicht gelungen, anhand des Instrumentes verlässliche Ergebnisse vorherzusagen. Dabei wird auch eine Weiterentwicklung dieses Instrumentes dadurch erschwert, dass niemand Interesse daran hat, ein funktionsfähiges NN zur Prognose von Aktienkurse der allgemeinen Öffentlichkeit mitzuteilen. Außerdem gibt es keine Möglichkeit herauszufinden, ob die Schwächen der Vorhersage ein Fehler der Anwendung sind, oder ob vielleicht überhaupt keine Struktur in den Daten, die das Instrument zur Schätzung der Aktienkurse verwendet, vorliegt.

Deshalb sollte bei der Anwendung der NN in der Betriebswirtschaft darauf geachtet werden, dass dieses Instrument für die jeweilige Problemlösung das geeignete Instrument darstellt. Bisher erwies sich die Anwendung am erfolgreichsten, wenn das zu bearbeitende Problem unstrukturiert war, aber eine Struktur in den Daten vorlag.

In den letzten Jahren wurden NN weltweit bei folgenden ökonomischen Anwendungen eingesetzt (HAWLEY et al., 1996, S.37):

1. *Finanzierungssimulationen*: Für das Aufdecken von Datenstrukturen in komplexen Finanzstrukturen in ihrer dynamischen Umwelt. Außerdem können hiermit das Cash Management, die Verteilung von Kapitalanlagen, Vorhersagen über Kreditkosten und deren Einfluss auf die Finanzierung der Firmen simuliert werden.
2. *Prognosen*: Zur Unternehmensfinanzierung ist es von großer Bedeutung, wie die Investoren auf verschiedene Unternehmenspolitiken reagieren. Wie sind die Reaktionen auf veränderte Dividendenpolitik, Umstellung der Bilanzierungsmethodik, Veränderung der Kapitalstruktur? Hierdurch kann die Finanzierungspolitik optimiert werden.
3. *Bewertung*: Durch das Aufdecken wünschenswerter Ziele einer Akquisition kann gezielt nach einem geeigneten Unternehmen gesucht werden.
4. *Kreditwürdigkeit für Lieferkredite*: Bewertung der Kunden für einen kurzfristigen Lieferkredit und die Ermittlung von Unternehmen mit einer schlechten Zahlungsmoral.
5. *Kreditwürdigkeitsprüfung durch Banken*: Auswerten von Bilanzen als zusätzliche Information der Entscheidungsunterstützung.
6. *Vermögens-Portfolio-Management*: Entscheidungshilfe für das Management bei unterschiedlichen Anlagemöglichkeiten, so dass Risiko und Ertrag optimal bewertet sind.
7. *Preisfestlegung von Neuemissionen*: Für die Bewertung neuer Aktien einer Gesellschaft.
8. *Technische Analysen*: Das Netz lernt die charttechnische Daten von Zeitreihen und nicht die Zeitreihen selbst.
9. *Fundamentale Analyse*: Aus Unternehmensdaten den Wert eines Unternehmens zu bestimmen.

Für diese betriebswirtschaftlichen Anwendungen liegen mittlerweile eine große Anzahl an Veröffentlichungen vor. Hier sind im deutschsprachigen Raum die Arbeiten von BISCHHOFF 1991, WILBERT, 1991, REHKUGLER und PODDIG 1991, EXERLEBEN 1992, ZIMMERMANN und HANTSCHERL 1992, KRAUSE 1993, BECKER 1994, BAETGE und UTHOFF 1997, PYTLIK 1995 und HAFNER 1997 zu nennen.

In der englischsprachigen Literatur kann einerseits auf eine Umfrage verwiesen werden, in der für die Periode von 1994 - 1998 die Veröffentlichungen systematisch erfasst worden sind. Hierbei handelt es sich um 72 wissenschaftliche Artikel über Anwendungen NN in der Betriebswirtschaft (WONG, LAI und LAM, 2000). Zum anderen befasst sich die Zusammenfassung von TRIPPI und TURBAN, 1996 mit 36 verschiedenen betriebswirtschaftlichen Anwendungen der NN. Zusätzlich gibt es viele

weitere Artikel, die gerade in jüngster Zeit veröffentlicht worden sind. Hier sind vor allem die Arbeiten von DESAI, CROOK und OVERSTREET 1996, WEST 2000, WU und WANG 2000 und SMITH und GUPTA 2000 zu nennen. Für den landwirtschaftlichen Sektor ist die Arbeit von GRAVES, BARNEY und JOHNSON, 1999 von besonderer Bedeutung. Neben diesen Veröffentlichungen gibt es eine Vielzahl weiterer. Die Liste erhebt keinen Anspruch auf Vollständigkeit.

3.4.3 Geschichtliche Entwicklung der Neuronalen Netze

Zum besseren Verständnis des heutigen Entwicklungsstands der NN soll hier kurz die Geschichte der NN vorgestellt werden. Es ist nichts Neues, dass der Mensch versucht das Gehirn nachzubilden. Seit langem beschäftigt er sich mit der Leistung des menschlichen Gehirns.

Die ersten Schritte der NN

Der Beginn der NN-Forschung wird auf das Jahr 1943 datiert. In diesem Jahr haben der Neurophysiologe *WARREN McCULLOCH* und der 18jährige Mathematiker *WALTER PITTS* den Aufsatz "*A Logical Calculus of the Ideas Immanent in Nervous Activity*" veröffentlicht (vgl. McCULLOCH und PITTS, 1943).

Hier zeigten sie, dass NN prinzipiell jede arithmetische oder logische Funktion berechnen können. Diese NN besaßen aber noch nicht die Fähigkeit zur Selbstmodifikation bzw. dem damit verbundenen Lernen. Zu diesem Problem erschien 1949 das Buch "*The Organization of Behaviour*" von dem Psychologen *DONALD HEBB* (vgl. HEBB, 1949). Hier wird die mittlerweile klassische *Hebb'sche Lernregel* als einfaches und universelles Lernkonzept individueller Neuronen beschrieben. In ihrer allgemeinen Form ist sie bis heute Basis fast aller neuronaler Lernverfahren.

1958 stellte der Psychologe *FRANZ ROSENBLATT* und seine Mitarbeiter das erste funktionsfähige NN vor. Dieses trug den Namen "*Perceptron*" und wurde damals als Meilenstein in der NN-Forschung gesehen. Es besaß schon die Fähigkeit zu lernen, Muster zu klassifizieren und dabei noch fehlertolerant zu sein; mithin konnte schon von einer gewissen Generalisierbarkeit gesprochen werden (SCHÖNEBURG et al., 1990, S.70).

Die Unterbrechung der Entwicklung

1969 wurde das vorübergehende Ende der NN eingeläutet. Durch die Arbeit "*Perceptrons*" von *MARVIN MINSKY* und *SEYMOUR PAPER*T wurde eine genaue mathematische Beweisführung des Perceptrons durchgeführt und damit gezeigt, dass das Modell viele wichtige Probleme gar nicht repräsentieren kann. So konnte nachgewiesen werden, dass die einfache nichtlineare Problemstellung, die logische *XOR-Funktion* und andere nichtlineare Zusammenhänge nicht gelöst werden konnten. Sie zogen daraus die Schlussfolgerung, dass auch mächtigere Modelle die gleichen

Probleme aufweisen würden, und damit das ganze Gebiet der NN ein "research dead - end" sei. So wurde dieses Forschungsgebiet in den folgenden Jahren vernachlässigt.

In diesen folgenden 15 Jahren der geringen Anerkennung dieses Forschungsgebietes wurden allerdings die Grundlagen für die Weiterentwicklung gelegt. So stellte der bekannte NN-Forscher *TEUVO KOHONEN* 1972 seine Arbeit vor. 1974 entwickelte *PAUL WERBOS* in seiner Dissertation an der Harvard-Universität bereits das *Backpropagation-Verfahren*, das allerdings erst ca. 10 Jahre später durch die Arbeiten von *RUMELHART und McCLELLAND* seine große Bedeutung erlangte. *STEPHEN GROSSBERG* veröffentlichte seine ersten Werke 1976, 1978 und 1980. Diese zeichnen sich durch eine detaillierte mathematische Analyse der darin vorgestellten neuronalen Modelle aus. Viele seiner Arbeiten behandeln das Problem, wie ein NN lernfähig bleiben kann, ohne dass bereits gelernte Muster durch neue Muster zerstört werden. *GROSSBERG* war einer der ersten, der die sigmoiden Aktivierungsfunktionen verwendet hat. Die Arbeiten von *McCELLEAND* und *RUMELHART* wurden 1981 veröffentlicht. *JOHN HOPFIELD*, ein bekannter Physiker, stellte 1982 mit seiner Arbeit einen neuen Bezug zur Festkörperphysik her und eröffnete hierdurch neue Perspektiven für die NN-Forschung. 1982 veröffentlichte auch *KOHONEN* seine Arbeit über selbstorganisierende Karten.

Die Wiederbelebung der NN

Die Wiederbelebung der NN erfolgt dann 1986 mit der Publikation des Lernverfahrens Backpropagation von *RUMELHART, HINTON und WILLIAMS* in "*Learning internal representations by error propagation*". Darin wurde das Lernverfahren "*Backpropagation*" als ein im Vergleich zu den bisherigen Lernverfahren sehr schnelles und robustes Verfahren für mehrstufige vorwärtsgerichtete Netze vorgestellt. Dieses Netz lässt sich als Gradientenabstiegsverfahren des Netzwerksfehlers einfach herleiten.

Seitdem wurden sehr viele Arbeiten in diesem Forschungsgebiet verfasst, die hier nicht alle erwähnt werden können. Es entstanden in den letzten Jahren eine Vielzahl von Zeitschriften mit dem Thema der Neuronale Netze (z.B. Neural Networks, Neural Computation, Neurocomputing, IEEE Trans. on Neural Networks usw.). Wegen der mittlerweile großen Bedeutung dieses Forschungsbereiches gründeten sich auch Gesellschaften, wie die ENNS (European Neural Networkd Society), die INNS (International Neural Network Society) und eine große Fachgruppe über neuronale Netze, die IEEE-Fachgruppe (ZELL, 1994, S. 33).


Nach einer explosionsartigen Entwicklung in diesem Forschungsgebiet Ende der 80er bis Mitte der 90er Jahre ist die Weiterentwicklung der NN Ende der 90er Jahre in eine Stagnationsphase eingetreten. Aber aufgrund vieler erfolgreicher praktischer Anwendungen wird die Weiterentwicklung stetig vorangetrieben.

3.4.4 Grundlagen eines biologischen Neuronalen Netzes

Das künstlich Neuronale Netz ist abgeleitet von dem biologisch Neuronalen Netz und dessen Funktionsweise. Das Nervensystem und Gehirn dient somit als Vorlage für die Entwicklung des künstlich Neuronalen Netzes.

Das Gehirn besteht aus etwa 100 Millionen Neuronen, von denen jedes ungefähr 1000 Dendriten mit insgesamt ca. 100 Milliarden Synapsen hat (ZELL, 1994, S.35f.). Die besondere Leistungsfähigkeit ergibt sich aus den verschiedenartigen Verbindungen und der parallelen Verarbeitung. Diese Verbindungen sind adaptiv, d.h. sie können sich vorübergehend oder aber auch über eine lange Zeit hinweg verändern. Auf dieser Anpassungsfähigkeit beruhen Lernvorgänge im menschlichen Nervensystem (HAFNER, 1997, S.121).

ABB. 9: NERVENSYSTEM



Quelle: NAUCK et al., 1994, S. 13

Grundbaustein von Nervensystemen sind die *Neuronen*. Diese sind die elementaren Verarbeitungseinheiten des menschlichen Gehirns. Sie bestehen aus vier wesentlichen Bestandteilen (ZELL, 1994, S.35f.):

- Zellkörper (*Soma*),
- Axon (*Neurit*),
- Dendriten und
- Synapsen.

Der *Zellkörper* ist an der eigentlichen Signalverarbeitung nicht direkt beteiligt. Er enthält einen Zellkern mit dem genetischen Material der Zelle und den Organellen. Er ist für den Stoffwechsel und für die Aufrechterhaltung der Funktionsfähigkeit der Gesamtzelle verantwortlich.

Das *Axon* übernimmt die Weiterleitung des Signals zu anderen verbundenen Neuronen. Es überträgt die Informationen mit Hilfe elektrischer Impulse, den sogenannten *Aktionspotentialen*. Die Weiterleitung der Aktionspotentiale erfolgt nicht ausschließlich durch physikalische, sondern auch durch chemische Prozesse, wobei die Erregung mit der Ionentheorie beschrieben wird (ROJAS, 1996, S.12ff.). Die Erregung erfolgt nach dem *Alles-oder-Nichts-Prinzip*, das besagt, dass erst wenn ein Schwellenwert überschritten wird, ein elektrischer Impuls weitergeleitet wird. Die Informationen liegen dann in einer Frequenz von Impulsen vor. Hierbei spielen die Dauer und Größe der Amplituden keine Rolle.

Die Verbindungsstelle zwischen den Enden eines *Axons* und den *Dendriten* eines anderen Neurons heißen *Synapsen*. Wenn ein elektrischer Impuls an einer Synapse ankommt, wird dieser chemisch weitergeleitet. Hierdurch wird die Informationsübertragung insgesamt verlangsamt. Zwischen einem Axon und dem Dendriten liegt ein schmaler Spalt, der sogenannte *synaptische Spalt*. Es existiert somit keine direkte Verbindung zwischen dem Axon und den Dendriten (ROJAS, 1996, S.18). Der in der Synapse ankommende Impuls erzeugt die Ausschüttung eines Transmitters, der in der präsynaptischen Membran in kleinen Bläschen enthalten ist. Dieser Transmitter diffundiert durch den synaptischen Spalt bis zur postsynaptischen Membran. Hierdurch wird die Ionendurchlässigkeit erhöht und ermöglicht somit die Änderung des Potentials am Dendriten, der schließlich die Impulse weiterleitet. Sobald an einem Dendriten ein genügend großes Reizpotential übermittelt worden ist, verändert sich das Spannungsgefälle innerhalb des Dendriten und des Zellkörpers in Folge einer erhöhten Permeabilität der Zellmembran.

Es wird heute angenommen, dass das Lernen durch die Veränderung an den Synapsen ermöglicht wird (SCHÖNEBURG, 1990, S.41). Es ist nachgewiesen worden, dass chemische Reaktionen existieren, die den Schwellenwert dauerhaft verändern können, indem sich die Membranpermeabilität ändert. Hierdurch kann eine Nervenzelle so trainiert werden, dass sich die Reizschwelle ändert (ROJAS, 1996, S.20f.).

Z.B. kann der *Gewöhnungseffekt* folgendermaßen beschrieben werden: Nachdem fortlaufend Aktionspotentiale an einer Synapse eingetroffen und übertragen worden sind, werden nach einer gewissen Zeitspanne immer weniger Aktionspotentiale weitergeleitet. Das liegt vermutlich daran, dass die Bläschen als Reaktion auf die mit hoher Frequenz eintreffenden Aktionspotentiale immer weniger Transmitterstoffe absondern. Ein Phänomen, das als chemische Ermüdung bezeichnet wird. Es konnte noch nicht

mit Sicherheit nachgewiesen werden, ob langzeitliche Veränderungen der synaptischen Übertragungen dem gleichen Prinzipien folgen. Aber es ist nicht umstritten, dass bei häufiger Benutzung der Synapse dieser Übertragungsweg "gebahnt" wird. D.h. der Hebbschen Hypothese zufolge sinkt der Übertragungswiderstand einer Synapse jedesmal, wenn gleichzeitig vor und nach der Synapse eine neuronale Aktivität besteht.

Jedes Neuron hat mindestens 1000 Synapsen, die die Verbindungen zu anderen Neuronen herstellen. Die Synapsen können unterschieden werden in anregende (aktivitätssteigernde, positive, excitatorische) und hemmende (aktivitätshemmende, negative, inhibitorische) Arten (PYTLIK, 1994, S.150).

Die Verarbeitungsgeschwindigkeit eines einzelnen Neurons ist verglichen mit heutigen Mikroprozessoren sehr gering. Da die Neuronen jedoch gleichzeitig arbeiten, entsteht so ein hochgradig parallel arbeitendes und extrem effizientes Signalverarbeitungssystem, welches jeder heute bekannten Computerarchitektur unvergleichbar überlegen ist (KINNEBROCK, 1994, S.13). Die Grundlage für die hohe Verarbeitungsgeschwindigkeit und Speicherkapazität ist das massiv-parallele Organisationsprinzip. Die Neuronenschichten unterliegen einem topographischen Organisationsprinzip, das heißt, benachbarte Neurone einer Schicht sind fast immer mit den benachbarten Neuronen der nächsten Schicht verbunden. Die Informationen werden räumlich verteilt gespeichert, damit der Zugriff auf alle Daten zur gleichen Zeit erfolgen kann. Dies bewirkt eine hohe Speicherkapazität des Gehirns.

3.4.5 Allgemeine Eigenschaften der künstlichen Neuronalen Netze

Bevor NN zum Einsatz kamen, wurden ökonomische und ökonometrische Probleme durch andere Verfahren gelöst. Aber durch ihre Eigenschaften schafften es die NN nach und nach sich in bestimmten Felder der Ökonomie und der Ökonometrie zu etablieren.

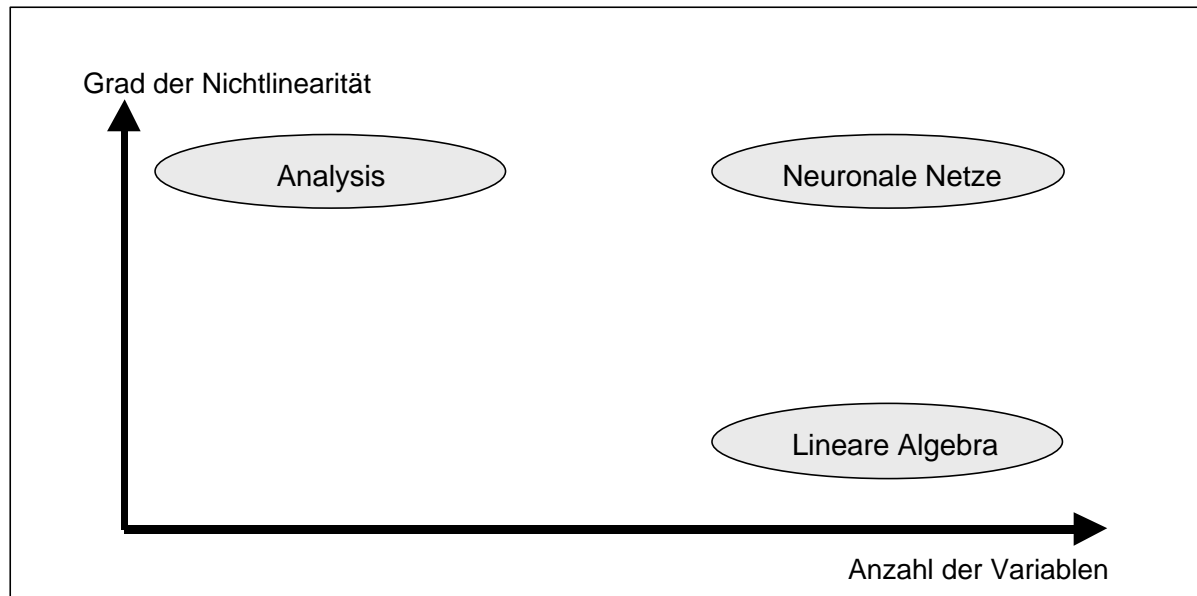
Die Aufgabe der Ökonometrie ist es, Basisfunktionssysteme zur Verfügung zu stellen, mit denen komplexe Systeme durch Daten festgelegt werden können (ZIMMERMANN, 1994, S.13). Bei der Festlegung eines ökonometrischen Modells ist die Dimension der Komplexität des abzubildenden Problems von entscheidender Bedeutung. Mathematisch betrachtet können zwei Arten von Komplexität hervorgehoben werden:

- Grad der Nichtlinearität und
- Anzahl der Variablen

Die gleichzeitige Verarbeitung von sehr vielen Variablen bei linearen Strukturen ist bei den heutigen Rechenanlagen kein Problem mehr. Auch die Modellierung von Nichtlinearitäten von einer (bzw. zwei) Variablen ist durch explizite mikroökonomische

Modelle leicht realisierbar. Sollen aber eine Modellierung von Nichtlinearitäten mit sehr vielen Variablen vorgenommen werden, so ist die Modellerstellung sehr komplex bzw. kaum realisierbar.

ABB. 10: DIMENSION DER KOMPLEXITÄT



Quelle: ZIMMERMANN, 1994, S. 13

Die dem Ökonom vorliegenden Beobachtungswerte entstammen einem Prozess, in dem sehr viele Variablen in Wechselwirkung zueinander stehen. Die Input-Output-Analyse versucht mit einer großen Anzahl von Variablen, für die nur lineare Zusammenhänge unterstellt werden, das Problem zu lösen. Auf der anderen Seite versucht der Ökonom in der Mikroökonomie, Zusammenhänge im Detail zu modellieren, beschränkt sich dafür in der numerischen Anwendung auf eine geringe Anzahl an Variablen.

Die wenigen Modelle, die versuchen, beiden Schwierigkeitsgraden gerecht zu werden, erfordern einen sehr großen Aufwand an Personal und technischer Ausstattung, um die meisten auftretenden Wechselwirkungen explizit zu modellieren. Die NN sind durch ihren Aufbau geeignet, nichtlineare Modelle mit einer großen Anzahl von Variablen in numerisch handhabbarer Weise darzustellen.

NN haben gegenüber herkömmlichen Ansätzen viele positive Eigenschaften (ZELL, 1994, S.26):

1. **Lernfähigkeit:** NN werden mit Trainingsdaten trainiert.
2. **Parallelität:** NN sind bereits vom Ansatz her massiv parallel.
3. **Verteilte Wissenspräsentation:** Bei fast allen neuronalen Modellen ist das „Wissen“ des NN in den Gewichten verteilt gespeichert.
4. **Höhere Fehlertoleranz:** Durch die verteilte Repräsentation können NN eine höhere Fehlertoleranz bei Ausfall einzelner Komponenten besitzen.
5. **Assoziative Speicherung von Informationen:** Informationen werden hier inhaltsbezogen gespeichert und nicht adressbezogen.
6. **Robustheit gegen Störungen oder verrauschte Daten:** NN haben den Vorteil, dass sie, wenn sie richtig trainiert sind, bei verrauschten Daten oder Störungen in den Eingabemustern meist weniger empfindlich reagieren als konventionelle Algorithmen.
7. **Generalisierungsfähigkeit** (SCHERER, 1997, S.5): NN können durch geeignete Trainingsbeispiele und entsprechenden Lernstrategien Entscheidungsregeln ausbilden, deren Gültigkeit über die Trainingsdaten hinausgehen und somit von allgemeiner Bedeutung sind.

Demgegenüber gibt es folgende negative Eigenschaften:

1. Wissenserwerb ist nur durch Lernen möglich.
2. NN können keine Analyse ihres eigenen Wissens oder Problemlösevorgangs durchführen, wie dies etwa die Erklärungskomponenten von Expertensystemen tun. Auch die Analyse des „Wissens“ eines Netzwerks ist schwierig.
3. Das Lernen erfolgt relativ langsam.

3.4.6 Prinzipien künstlicher Neuronaler Netze

Das natürliche Nervensystem ist die Vorlage für die Konstruktion der künstlichen NN. Die Theorie der NN hat sich als geeigneter Rahmen erwiesen, ökonomische Problemstellungen zu formulieren und in diesem Rahmen mathematische Techniken zu entwickeln, um die bestehenden Probleme anzugehen.

Die Bestandteile eines künstlichen neuronalen Netzwerkes sind stark idealisierte Neuronen. Sie bestehen in Anlehnung an das biologische Vorbild aus drei Komponenten: einem Zellkörper, einem Dendriten, welcher die Eingabe des Netzes in die Zelle aufsummiert und einem Axon, welches die Ausgabe einer Zelle nach außen

weiterleitet, sich verzweigt und mit den Dendriten nachfolgender Neurone über Synapsen in Kontakt tritt. Die Stärke der Synapsen wird meist durch einen numerischen Wert, dem Verbindungsgewicht, dargestellt.

Die Bestandteile eines künstlichen Neuronalen Netzes sind (ZELL, 1994, S.72):


- **Neuronen:** Diese Zellen besitzen folgende Bestandteile:
 - **Aktivierungszustand**
 - **Aktivierungsfunktion**
 - **Ausgabefunktion**
- **Verbindungsnetzwerk:** Die räumliche Gestaltung des Netzes.
(*Topologie des Netzes*)
- **Propagierungsfunktion:** Sie gibt an, wie sich die Netzeingabe eines Neurons aus den Ausgaben der anderen Neuronen und den Verbindungsgewichten berechnet.
- **Lernregel:** Die Lernregel ist ein Algorithmus, gemäß dem das Neuronale Netz lernt.

3.4.6.1 Das Neuron

Zuerst werden die einzelnen Bestandteile des Neuronalen Netzes näher beschrieben. Die Verarbeitungseinheit der NN kann man sich als einfache Automaten oder Prozessoren vorstellen und werden als Neuronen bezeichnet. In Abhängigkeit ihres durch eine reelle Zahl gegebenen aktuellen Zustandes, *den Aktivierungszustand*, und ihrer Eingabe wird ein neuer Zustand berechnet und eine Ausgabe generiert.

Definition

Ein *künstliches Neuron* n_j ist ein Tupel $(\vec{x}, \vec{w}, f_a, f_o, a, o)$ bestehend aus einem Eingabevektor $\vec{x} = (x_1, \dots, x_n)$, einem Gewichtsvektor $\vec{w} = (w_1, \dots, w_n)$, einer Aktivierungsfunktion f_a mit $f_a: \mathbb{R}^n \times \mathbb{R}^n \rightarrow \mathbb{R}$ und einer Ausgabefunktion f_o , für die gilt $f_o: \mathbb{R} \rightarrow \mathbb{R}$. Dabei wird durch $f_a = a$ der Aktivierungszustand und durch $f_o = o$ der Ausgabewert erzeugt, der an die nachfolgenden Neuronen über die Axonkollaterale weiter geleitet wird.

Abb. 11: Darstellung eines künstlichen Neurons

Quelle: in Anlehnung an ZELL, 1994

Die Eingabe des Neurons net (Propagierungsfunktion) in Abb. 11 berechnet sich nach

$$net = \sum_{i=1}^n x_i w_i$$

aus der Summe der Eingabewerte bzw. Ausgabewerte der Vorgängerzellen x_i multipliziert mit dem jeweiligen Gewicht w_i .

Die Ausgabefunktion $f_o(net)$ erzeugt den Ausgabewert o des Neurons (vgl. Abb. 11). In den üblichen NN sind die *Aktivierungs-* und *Ausgabefunktion* (f_a und f_o) eines Neurons gleich, so dass für jedes Neuron die Identität als Ausgabefunktion gewählt wird.


Die *Aktivierungsfunktion* bestimmt für jedes Neuron den aktuellen *Aktivierungszustand* in Abhängigkeit von der vorhergehenden Aktivierung. Der Grad der Aktivierung des Neurons wird als *Aktivierungszustand* a bezeichnet.

Der Aktivierungszustand a eines Neurons wird in der technischen Realisierung unterschiedlich dargestellt. Es wird unterschieden zwischen (quasi-) kontinuierlichen und diskreten Wertebereichen. Im Falle kontinuierlicher Wertebereiche wird wiederum unterschieden zwischen den Modellen, die alle reellen Zahlen (reals, floats) als Werte zulassen und denen, die ein Intervall verwenden. Die meisten Modelle beschränken die Aktivierung auf ein Intervall, beispielsweise $[0, 1]$ oder $[-1, +1]$. Dies kommt daher, dass diese Modelle meistens eine nichtlineare, häufig sigmoide *Aktivierungsfunktion* und die Identität als *Ausgabefunktion* verwenden, wodurch die Ausgabe identisch mit der Aktivierung wird, und der Wertebereich der *Aktivierungsfunktion* den Wertebereich des *Aktivierungszustandes* angibt.

Bei der Vorstellung von biologischen Neuronen sah man (vgl. Kapitel 3.4.4), dass für die Auslösung eines Aktionspotentials ein gewisser Schwellenwert S überschritten werden muss. Dies motiviert zur Verwendung von binären *Schwellenwertfunktionen* der Art:

$$f_a \left(\sum_{i=1}^n x_i w_i \right) = \begin{cases} 1: & \text{falls } \sum_{i=1}^n x_i w_i \geq S \\ 0: & \text{sonst} \end{cases}$$

ABB. 12: SCHWELLENWERTFUNKTION: EINE HEAVISIDE SPRUNGFUNKTION




Quelle: in Anlehnung an ZIMMERMANN, 1994, S.5

Diese Art der *Aktivierungsfunktion* modelliert allerdings nicht die Intensität der aufeinanderfolgenden Aktionspotentiale eines biologischen Neurons. Diese wird durch die linearen Aktivierungsfunktionen erreicht. Da der zeitliche Abstand, in dem die Aktionspotentiale durch die Nervenzelle weitergereicht werden, nach unten beschränkt ist, sollte in dem formalen Neuronenmodell eine beschränkte Aktivierungsfunktion Verwendung finden. Solche Aktivierungsfunktionen lassen sich durch semilineare Funktionen der Art beschreiben:

$$f_a \left(\sum_{i=1}^n x_i w_i \right) = \begin{cases} 1 & : \text{falls } \sum_{i=1}^n x_i w_i > s' \\ 0 & : \text{falls } \sum_{i=1}^n x_i w_i < s \\ \frac{\left(\sum_{i=1}^n x_i w_i \right) - s}{s' - s} & : \text{sonst} \end{cases}$$

Die Aktivierungsfunktion f_a weist für die Werte zwischen s und s' einen linear steigenden Verlauf auf (Abb. 13). Sie beinhaltet keine Sprungstelle wie die Sprungfunktion.

ABB. 13: SEMILINEARE FUNKTION



Quelle: in Anlehnung an NAUCK, 1996, S.21


Es scheint allerdings viel sinnvoller, die Aktivierung bzw. Ausgabe durch "glattere", d.h. differenzierbare Funktionen zu beschreiben. Solche differenzierbare und beschränkte Funktionen sind z.B. "s-förmige" oder auch "sigmoide" Funktionen.

Die **Definition** lautet:

Eine Funktion $s_c: \mathbb{R} \rightarrow [0, 1]$ heißt "sigmoide" oder "s-förmige" Funktion, wenn sie monoton wachsend und differenzierbar ist und wenn

$$\lim_{I \rightarrow -\infty} s_c(I) = K_1 \text{ und } \lim_{I \rightarrow +\infty} s_c(I) = K_2 \quad \text{mit } K_1 < K_2$$

gelten.

ABB. 14: HÄUFIG VERWENDETE AKTIVIERUNGS- BZW. AUSGABEFUNKTIONEN

Quelle: ZELL, 1994, S. 77

Die Abb. 14 stellt Aktivierungs- bzw. Ausgabefunktionen graphisch dar. Bei der Identitätsfunktion entspricht die Funktionseingabe net_j des Neurons n_j dem Aktivierungszustand a_i bzw. Ausgabewert o_j (out_j). Bei der "linear bis Sättigungs-Funktion" handelt es sich um eine weitere semilineare Funktionsform, bei der abgebildeten binären Schwellenwertfunktion um eine Sprungfunktion und bei der logistischen, sin- und tanh-Funktion um s-förmige Funktionsformen.


Schwellenwert

Mathematisch gibt der *Schwellenwert* (auch *bias* genannt) die Stelle der größten Steigung einer monoton wachsenden Aktivierungsfunktion an. Biologisch entspricht er der Reizschwelle, die erreicht werden muss, damit das Neuron "feuern" kann. In

Simulationen kann dieser Schwellenwert unterschiedlich realisiert werden, entweder als Parameter in der Aktivierungsfunktion oder über einen zusätzlichen, gewichteten Eingang.

Wenn der Schwellenwert als Parameter von f_a realisiert wird, so entsteht der Nachteil, dass die Schwellenwerte üblicherweise während der Lernphase mittrainiert werden müssen. Alternativ bietet sich die Hinzunahme einer zusätzlichen Bias-Eingabe an.

ABB. 15: NEURON MIT BIAS - EINGANG



Quelle: in Anlehnung an ZELL, 1994

Neurone als Entscheidungsprozess

Wird die mathematische Theorie der NN betrachtet, so kann festgestellt werden, dass sie zunächst konzipiert worden ist, um biologische Prozesse beschreiben bzw. erklären zu können. Hierauf aufbauend soll beschrieben werden, wie eine ökonomische Umsetzung der NN aussehen könnte. Einzelne Neurone repräsentieren Entscheidungsprozesse, und NN modellieren die Wechselwirkungen vieler Einzelentscheidungen. Die mikroskopische Verhaltensmodellierung eines Agenten bei der Entscheidungsfindung kann in verschiedener Weise erfolgen. Die Überlagerung vieler Entscheidungen in einem Netzwerk leitet daraus die makroskopische Konsequenz ab. Lernen in einem NN kann als die Aufspaltung makroskopischer Beobachtungsdaten in ein mikroskopisches Entscheidungskalkül gesehen werden.

Das Neuron ist aus der Sicht von ZIMMERMANN ein Entscheidungsmodell. Es durchläuft bei der Entscheidungsfindung drei Hauptelemente (ZIMMERMANN, 1994, S.4):

- Informationsfilterung,
- Informationsüberlagerung und
- Übergang zu einer Ja/Nein - Aussage.

Ein Neuron arbeitet genauso wie das Entscheidungsmodell. In einem Neuron fließen sehr viele Informationen zusammen. Zuerst unterliegen die Informationen einer Filterung, die folgendermaßen umgesetzt wird: Durch die Multiplikation der Informationen x_i mit Gewichten w_i kann der Einfluss der Informationen auf die weitere Verarbeitung gesteuert werden. Ist das Gewicht Null, so wird die vorhandene Information nicht weiterverarbeitet. Durch Nullsetzung eines Teils der Eingangsgewichte lässt sich so eine Modellierung des *Informationsfiltervorganges* erreichen.

Nach der Informationsfilterung müssen die ausgewählten Informationen zu einer einzigen Gesamtgröße überlagert werden. Um dies mathematisch umzusetzen, wird die gewichtete Summe aller gefilterten Informationen gebildet. Dies könnte durch sehr komplexe Funktionen erfolgen, aber die gewichtete Summe erfüllt gerade die Minimalforderung, die eine Wechselwirkung der Faktoren und ihre Zusammenfassung zu einer Größe auszudrücken.

Danach muss eine *Ja/Nein-Aussage* mathematisch formuliert werden. Hierfür wird eine nichtlineare Funktion benötigt. Dies ist die sogenannte *Aktivierungsfunktion*. Entsprechend dem biologischen Vorbild muss die Summe der gewichteten, ausgefilterten Informationen einen Schwellenwert erreichen, damit die Information weiterverarbeitet wird. Im mathematischen Modell lässt sich das durch die Anwendung einer Sprungfunktion (vgl. Abb.12) ausdrücken.

Weil die Sprungfunktion den Nachteil besitzt, dass sie nicht überall differenzierbar ist, und dadurch der Gebrauch der Differentialrechnung stark eingeschränkt wäre, wird statt dieses Funktionstyps eine Logistische oder Tangens Hyperbolicus Funktion verwendet (vgl. Abb.14). Mit diesen beiden Funktionstypen lassen sich mathematisch gesehen die *Ja/Nein-Aussage* formulieren. Mit Hilfe der Größe der Gewichte können die Ergebnisse der Funktion modelliert werden. Je größer die Gewichte sind, desto eher genügen kleinere Änderungen der Inputfaktoren, um von einem Extrem der sigmoiden Funktion zum anderen überzugehen. So kann jede gewünschte Näherung an eine *Ja/Nein-Aussage* erzielt werden. Dieses "Alles-oder-Nichts-Verfahren" mit einer sigmoiden Funktion kann für eine Klassifizierung von zwei Klassen mit unscharfen Grenzen verwendet werden.

3.4.6.2 Das Verbindungsnetzwerk

Ein NN kann als Modell der Wechselwirkung vieler Entscheidungen angesehen werden. Die einzelnen Neuronen, die in diesem Fall die elementaren Entscheidungszellen sind, lassen sich zu einem Mehrschichtnetzwerk kombinieren. Die Neuronen sind miteinander in unterschiedlicher Weise verbunden (RUMELHART et al., 1986, S.49ff.). Die Verbindungen zwischen den Neuronen kennzeichnen das Wissen des NN und bestimmen die Reaktion des Systems. Die Verbindungen werden

üblicherweise als Gewicht w_{ij} angegeben, wobei es sich hier um das Verbindungsgewicht zwischen den Neuronen n_i und n_j handelt. Das Neuron n_j steht in Verbindungen zu seinen Vorgängerneuronen $n_1 .. n_k$. Den Verbindungen zwischen den $n_1 .. n_k$ zu n_j sind Gewichte w_{ij} zugeordnet. Die Ausgabe von Neuron n_j wird nach entsprechender Weiterverarbeitung an andere Neuronen oder an die Ausgabe weitergeleitet (SCHERER, 1997, S.45).

Positive Gewichte belegen einen erregenden Einfluss, negative Gewichte einen hemmenden Einfluss. Ist das Gewicht gleich null, so besteht keine Verbindung zwischen den beiden Neuronen. Der absolute Wert beschreibt die Stärke der Verbindung. Bedeutsam ist auch die Unterscheidung in gerichtete und ungerichtete Verbindungen. Gerichtete Verbindungen haben eine festgelegte Richtung des Informationsflusses, ungerichtete Verbindungen hingegen erlauben den Informationsfluss in beide Richtungen.

Definition

Ein *Neuronales Netz* ist ein Paar (N, V) mit einer Menge N von Neuronen und einer Menge V von Verbindungen. Es besitzt die Struktur eines gerichteten Graphen, für den die folgenden Einschränkungen und Zusätze gelten:

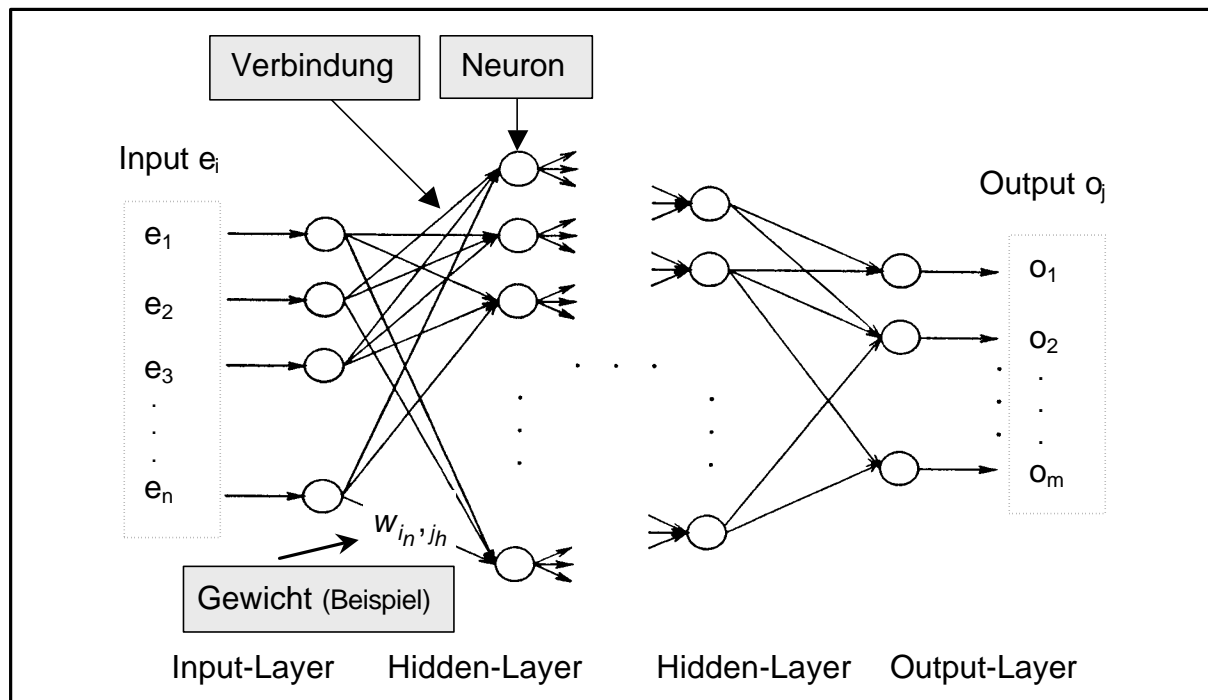
- Die Knoten des Graphen heißen Neuronen.
- Die Kanten heißen Verbindungen.
- Jedes Neuron kann eine beliebige Menge von Verbindungen empfangen, über die das Neuron seine Eingaben erhält.
- Jedes Neuron kann genau eine Ausgabe über eine beliebige Menge von Verbindungen aussenden.
- Das NN erhält aus Verbindungen, die der „Außenwelt“ entspringen, seine Eingaben und gibt seine Ausgaben über in der „Außenwelt“ endende Verbindungen ab.

Alle *Verbindungen*, die von anderen Neuronen zu einem einzelnen Neuron n_i gehen, ergeben den Eingavektor \vec{x}_i von i . Bei den meisten NN wird die Eingabe gewichtet. Die Verbindungsstruktur (Topologie) kann in Form einer Matrix beschrieben werden.

In der Matrixschreibweise $W = [w_{ij}]$ gilt:

- $w_{ij} = 0$: Keine Verbindung von Neuron i zu Neuron j .
- $w_{ij} < 0$: hemmende Verbindung der Stärke $|w_{ij}|$
- $w_{ij} > 0$: anregende Verbindung der Stärke $|w_{ij}|$.

ABB. 16: MEHRSCICHTIGES NEURONALES NETZ



Quelle: Eigene Darstellung

Das Netzwerk ist aus mehreren Schichten aufgebaut (vgl. Abb. 16). Es existieren grundsätzlich drei verschiedene Schichttypen:


- **Input-Layer**, deren einzige Aufgabe es ist, Informationen aus der Umwelt aufzunehmen. In ihnen findet keine Überlagerung verschiedener Variablen statt.
- **Hidden-Layer**, hier werden die Informationen verarbeitet. Der Vektor der Outputs dieser Schicht dient dann als Input der nächsten Neuronenschicht. Dieses Schema kann iterativ fortgesetzt werden.
- **Output-Layer**, deren Aufgabe ist es, das Ergebnis auszugeben.

Die Neuronen innerhalb einer Schicht sind nicht untereinander verbunden. Die Schichten sind aber durch viele Verbindungen miteinander verknüpft. Bei dem Netzwerktyp wie in Abb. 16 ist der Informationsfluss stets nur in einer Richtung, nämlich von dem Input-Layer Richtung Output-Layer. Mit Hilfe des Hidden-Layers kann eine beliebige komplexe Input - Output Abbildung dargestellt werden. Es gibt andere Netzwerktypen mit mehreren Hidden-Layer und/oder Rückkopplungen des Informationsflusses.

Der *Hidden-Layer* ist bei einem drei- und mehrschichtigen Netz von dem Input-Layer und dem Output-Layer eingeschlossen. Da diese Schicht keine Daten von der Umwelt direkt empfängt bzw. direkt an die Umwelt abgibt, heißt sie auch versteckte Schicht. Die von den Neuronen des Input-Layers übermittelten Werte verarbeiten die Neuronen des Hidden-Layers. Die Bedeutung, die eine originäre oder eine schon verarbeitete

Information für ein Neuron besitzt, wird durch die Stärke der Verbindung, das Verbindungsgewicht, dargestellt. Die Neuronen in dem Hidden-Layer übernehmen die eigentliche Informationsverarbeitung im mehrschichtigen Netz.

ABB. 17: BEISPIEL-TOPOLOGIEN UND IHRE VERBINDUNGSMATRIZEN



Quelle: ZELL, 1994, S.79

NN lassen sich gemäß der folgenden *Topologien* klassifizieren (vgl. Abb. 17):

➤ *Netze ohne Rückkopplung (feedforward-Netze)*

Bei diesen Netzen existiert kein Pfad, der von einem Neuron direkt oder über zwischengeschaltete Neuronen wieder zu dem Neuron zurückführt. Mathematisch ist die Topologie des Netzes also ein azyklischer Graph. In der Matrixdarstellung ist daher die obere Dreiecksmatrix mit Werten ungleich Null besetzt.

1. Ebenenweise verbundene Feedforward-Netze:

Diese Netze sind in mehrere Ebenen (Schichten) eingeteilt. Es gibt nur Verbindungen von einer Schicht zur nächsten.

2. Allgemeine Feedforward-Netze (mit shortcut connections)

Bei diesen Netzen gibt es neben den Verbindungen zwischen aufeinanderfolgenden Ebenen auch solche, die Ebenen überspringen, d.h. die direkt von einem Neuron in Ebene k zu einem Neuron in Ebene $k+i$ mit $i > 1$ verlaufen.

Bei ebenenweise verbundenen Feedforward-Netzen wird von vollständig oder total verbundenen Netzen gesprochen, falls jedes Neuron einer Schicht mit jedem Neuron der Schicht verbunden ist.

➤ Netze mit Rückkopplungen (recurrente Netze)

Netze mit Rückkopplungen werden meistens in die Klassen der Netze mit direkten Rückkopplungen (*direct feedback*), Netze mit indirekten Rückkopplungen (*indirect feedback*) und Netze mit Rückkopplungen innerhalb einer Schicht (*lateral feedback*) und vollständig verbundene Netze unterteilt.

1. Netze mit direkten Rückkopplungen (*direct feedback*)

Diese Netze erlauben es, dass ein Neuron seine eigene Aktivierung über eine Verbindung von seinem Ausgang zu seinem Eingang verstärkt oder abschwächt. Diese Verbindungen bewirken oft, dass Neuronen die Grenzzustände ihrer Aktivierungen annehmen, weil sie sich selbst verstärken oder hemmen.

2. Netze mit indirekten Rückkopplungen (*indirect feedback*)

Bei diesen Netzen gibt es eine Rückkopplung von Neuronen höherer Ebenen zu Neuronen niedriger Ebenen. Diese Art der Rückkopplung ist nötig, wenn eine Aufmerksamkeitssteuerung auf bestimmte Bereiche von Eingabeneuronen oder auf bestimmte Eingabemerkmale durch das Netz erreicht werden soll.

3. Netze mit Rückkopplungen innerhalb einer Schicht (*lateral feedback*)

Netze mit Rückkopplungen innerhalb derselben Schicht werden oft für Aufgaben eingesetzt, bei denen nur ein Neuron in einer Gruppe von Neuronen aktiv werden soll. Jedes Neuron erhält dann hemmende (inhibitorische) Verbindungen zu anderen Neuronen und oft noch eine aktivierende (exzitatorische) direkte Rückkopplung von sich selbst. Das Neuron mit der stärksten Aktivierung (der Gewinner) hemmt dann die anderen Neuronen. Daher heißt eine solche Topologie auch *winner takes all*-Netzwerk.

4. Vollständig verbundene Netze

Vollständig verbundene Netze haben Verbindungen zwischen allen Neuronen. Sie sind insbesondere als Hopfield-Netze bekannt geworden. Bei diesen gibt es noch zwei weitere Restriktionen: Die Verbindungsmatrix muss symmetrisch sein und die Diagonale darf nur Nullen enthalten.

Netze mit Rückkopplungen werden auch eingesetzt, um Zeitabhängigkeiten bei Daten, wie z.B. die Struktur einer Schwingung, modellieren zu können. Über die Rückkopplung erhält man als Netzeingabe nicht nur die „neuen“ Daten, sondern auch wieder die (bereits verarbeiteten) „alten“ Daten.

Bei Klassifizierungen mit statistischen Daten, wie sie bei der statistischen Jahresabschlussanalyse vorliegen, eignet sich somit am besten der Einsatz von "Ebenenweise verbundene Feedforward-Netze".

Multilayer-Perceptron (MLP)

Das am häufigsten eingesetzte vorwärtsgerichtete Netz, das aus einem Input-Layer, einem oder mehreren Hidden-Layers und einen Output-Layer besteht, ist das Multilayer-Perceptron (MLP).

Definition für ein MLP (NAUCK et al., 1994, S.72)

Ein Multilayer-Perceptron ist ein Neuronales Netz $MLP = (U, W, f_a, f_o)$ das folgende Charakteristika aufweist:

- $U = U_1 \cup \dots \cup U_n$ ist eine Menge von Neuronen und wobei $n \geq 3$ vorausgesetzt wird. U_1 heißt Input-Layer und U_n Output-Layer. Die U_i mit $1 < i < n$ werden Hidden-Layer genannt.
- Das Verbindungsnetzwerk ist durch die Abbildung $W: U \times U \rightarrow IR$ festgelegt, wobei nur Verbindungen zwischen direkt aufeinanderfolgenden Schichten existieren. Formal gilt also $W(u, v) \Rightarrow u \in U_i, v \in U_{i+1}$ für alle $i \in \{1, \dots, n-1\}$.
- f_a ordnet jeder Einheit $u \in U$ eine Aktivierungsfunktion $f_{a_u}: IR \rightarrow [0, 1]$ zur Berechnung der Aktivierung zu. $f: IR \rightarrow [0, 1]$ ist dabei eine für alle Einheiten fest gewählte nichtlineare Funktion.
- f_o ordnet jeder Einheit $u \in U$ eine Ausgabefunktion $f_{o_u}: IR \rightarrow [0, 1]$ zur Berechnung der Ausgabe o_u zu.

Das MLP zeichnet sich durch seine vielseitigen Einsatzmöglichkeiten aus. Es ist neben der Klassifizierung auch für Mustererkennung und Punktprognosen geeignet. Die Fähigkeit, beliebige stetige Funktionen zu approximieren (vgl. PODDIG, 1992), macht das MLP für die Klassifizierung von Jahresabschlüssen besonders geeignet, denn es ist in der Lage, eine Trennfunktion, die durch das Datenmaterial vorgegeben ist, zu approximieren. Neben diesem Netzwerkmodell existieren eine Vielzahl an weiteren Netzwerkmodellen (ZELL, 1994 und ROJAS, 1996).

3.4.6.3 Lernalgorithmen

Um ein NN entwickeln zu können, mit dem man die Strukturen in den Daten (Jahresabschlussanalysen) erkennen und speichern kann, sind Lernalgorithmen notwendig.

Eine der zentralen Eigenschaften der NN ist die *Lernfähigkeit*. Im einfachsten Fall wird darunter verstanden, dass ein Netz eine gegebene Menge von Daten reproduzieren lernt. Hierzu muss eine geeignete netzinterne Repräsentation der Daten gefunden werden. Die Lernalgorithmen legen dabei fest, mit welcher Strategie diese interne Repräsentation berechnet wird. Es gibt grundsätzlich eine Reihe von Ansatzmöglichkeiten (SCHERER, 1997, S.57):

- Aufbau und Löschung von Verbindungen.
- Aufbau und Löschung von Neuronen.
- Modifikation der Gewichtungen von Verbindungen.
- Modifikation von Parametern innerhalb des Neurons (Variation von internen Parametern der Aktivierungsfunktion, Schwellenwerten usw.).

Bei Klassifizierungsmodellen erkennt das NN anhand von Trainingsdaten der Vergangenheit eine Struktur in den Daten. Grundsätzlich können alle NN gemäß der verwendeten Lernverfahren in drei Kategorien unterschieden werden:

1. **Überwachtes Lernen** (*supervised learning*)

Beim überwachten Lernen gibt ein „externer“ Lehrer dem Netz zu jeder Eingabe die korrekte Ausgabe oder die Differenz der tatsächlichen Ausgabe zu der korrekten Ausgabe an. Anhand dieser Differenz wird dann über die Lernregel das Netz modifiziert. Diese Technik setzt allerdings die Existenz von Trainingsdaten voraus, die aus Paaren von Ein- und Ausgabedaten bestehen.

2. **Bestärkendes Lernen** (*reinforcement learning*)

Der Unterschied zum überwachten Lernen besteht hier darin, dass dem Netz lediglich mitgeteilt wird, ob seine Ausgabe korrekt oder inkorrekt war. Das Netz erfährt nicht den exakten Wert des Unterschiedes.

3. **Unüberwachtes Lernen** (*unsupervised learning*)

Beim unüberwachten Lernen erhält das NN keine zusätzlichen externen Informationen zur Veränderung der Gewichte außer den Eingangsdaten selbst. Das NN sucht innerhalb der Eingangsdaten nach Regelmäßigkeiten und Gemeinsamkeiten, anhand derer es die Verbindungsgewichte justieren kann.

Um die Abweichung zwischen Zielwert und Output beim überwachten Lernen zu minimieren, existieren verschiedene Lernregeln (ZELL, 1994, S.84):

- Hebbsche Lernregel
- Delta Lernregel
- Backpropagation Lernregel

Hebbsche Lernregel

Im Gehirn erfolgt das Lernen zum Teil durch Änderung der Synapsenstärken. Der erste, der hierzu eine Aussage machte, war der Psychologe DONALD HEBB. Er stellte die Hypothese auf, dass im Gehirn die stärkende Eigenschaft der Synapse sich dann vergrößert, wenn die Neuronen vor und hinter der Synapse gleichzeitig aktiv sind. Der Nachweis derartigen Verhaltens von Zellen konnte allerdings erst 1989 an der Universität Yale an Rattengehirnen nachgewiesen werden. Aber auf dieser Grundlage formulierte HEBB schon 1949 die *Hebbsche Lernregel*, die als Grundlage für die meisten Lernregeln gilt. Sie lautet (KINNEBROCK, 1994, S.23):

"Wenn das Neuron n_j eine Eingabe vom Neuron n_i erhält und beide gleichzeitig stark aktiviert sind, dann erhöht sich das Gewicht w_{ij} , d.h. die Stärke der Verbindung von i nach j)"

Die mathematische Form lautet: $\Delta w_{ij} = h \times o_i \times a_j$

Hierbei ist Δw_{ij} die Änderung des Gewichts w_{ij} , h eine Konstante (Lernrate), o_i die Ausgabe der Vorgängerzelle i und a_j die Aktivierung der Nachfolgerzelle j .

Delta Regel

Eine Spezialisierung der *Hebbsche Lernregel* ist die *Delta Lernregel*. Dieser verbesserte Lernalgorithmus liefert ein Beispiel für das Lernen mit Korrektur. Abweichungen zwischen dem Zielwert des Outputs o'_j und dem aktuellen Output o_j werden nicht nur mit Verstärkung in einer Richtung korrigiert, sondern der Fehler wird für den getesteten Eingabevektor vollständig behoben. Die *Delta Lernregel* lautet folgendermaßen (RUMELHART und McCLELLAND, 1986):

$$\Delta w_{ij} = h \times o_i \times (o'_j - o_j) = h \times o_i \times d_j$$

d_j ist die Differenz zwischen dem Zielwert des Outputs o'_j und dem aktuellen Output o_j . Diese Lernregel ermöglicht es, Gewichtsveränderungen so durchzuführen, dass ein bestimmter Eingabevektor mit einem gewünschten Ausgabevektor assoziiert (SCHÖNEBURG, 1990, S.87f.). Ergibt sich eine Differenz, werden die Gewichte adaptiert, sonst wird nicht gelernt. Die *Delta Lernregel* ist nur für zweischichtige Netzwerke definiert, da der gewünschte Output eines Neurons nur im Output-Layer, nicht aber für die Hidden-Layer beschrieben werden kann.

Backpropagation Lernregel

Eine Lernregel für ein NN mit mehreren Schichten, wie beispielsweise das MLP, ist das sogenannte *Backpropagation Lernverfahren*. Dieses Verfahren stellt eine Verallgemeinerung der *Delta Lernregel* dar. Durch das Backpropagation Lernverfahren wird eine Berechnung der Hidden-Layer definiert. *Die Backpropagation Lernregel*, auch Fehlerrückführungsmethode genannt, ist die zur Zeit wirksamste und meist eingesetzte Lernmethode zum Trainieren mehrschichtiger Netze. Sie ist eine Gradienten-Abstiegsmethode und wurde von RUMELHART, HINTON, und WILLIAMS (1986) erstmals ausführlich beschrieben.

Die *Backpropagation Lernregel* hat den Vorteil, dass ein mathematischer Formalismus vorliegt, der auf jedes Netz anwendbar ist und kein spezielles Eingehen auf die Besonderheiten der zu lernenden Funktion erfordert. Leider ist die Zahl der Lernschritte oft sehr hoch, so dass die Lernphase sehr rechenintensiv ist.

Der *Backpropagation Algorithmus* stellt zunächst nur ein Verfahren zur Berechnung des Wertes der ersten Ableitungen einer Zielfunktion nach den Netzwerkparametern dar. Von einem Gradientenverfahren wird gesprochen, wenn die Suchrichtung zur Minimierung des negativen Gradienten der Fehlerfunktion verwendet wird. Hierbei handelt es sich um eine Funktion, die den Fehler minimiert, der bei gegebenen Gewichten über alle Trainingsdaten aufsummiert wird. Mit dem Gradientenverfahren, der Methode des steilsten Abstiegs, wird versucht, möglichst schnell ein globales Minimum der Fehlerfunktion zu finden, d.h. eine Konfiguration der Gewichte, bei der die Fehlersumme über alle Trainingsdaten minimal ist.

Fehlerermittlung eines NN

Ein NN liefert für einen Eingabevektor \vec{x} und eine fest vorgegebene Belegung aller Gewichte im Netz stets die gleiche Ausgabe, dadurch lässt sich das Ein-/Ausgabeverhalten des Netzes als Funktion o_{Netz} darstellen. Sei q die Gesamtanzahl der Gewichte im Netz und

$$\vec{w} = (\vec{w}_1, \dots, \vec{w}_n) \in \mathbb{R}^q$$

der Gewichtsvektor des Netzes, dann gilt für \vec{o}

$$\vec{o} = o_{\text{Netz}}(\vec{x}, \vec{w}).$$

Für ein gegebenes Trainings- oder Testdatum (\vec{x}, \vec{o}^1) ist der Fehler (Güte) der Netzausgabe zunächst gegeben durch $\vec{o}^1 - \vec{o}$. Wenn f als die „zu lernende Funktion“ bezeichnet wird, so gilt $\vec{o}^1 = f(\vec{x})$ und dementsprechend ist der Fehler $f(\vec{x}) - o_{\text{Netz}}(\vec{x}, \vec{w})$.

Es ist nicht sinnvoll zwischen positiven und negativen Fehlern zu unterscheiden. Deshalb wird üblicherweise der quadratische Fehler verwendet: Der quadratische Fehler F eines Backpropagation-Netzes ist für ein gegebenes \vec{x} und \vec{w} definiert durch:

$$F(\vec{x}, \vec{w}) := |f(\vec{x}) - o_{\text{Netz}}(\vec{x}, \vec{w})|^2$$

Die obige Definition erhält nur die Aussage über die Güte des Netzes hinsichtlich der konkreten Eingabe \vec{x} . Gewünscht ist jedoch eine Güteaussage hinsichtlich aller möglichen Eingabevektoren. Hierzu muss der quadratische Fehler für möglichst viele Eingabevektoren \vec{x}_k mit $k = 1, 2, \dots, n$ bestimmt und danach gemittelt werden.

Der **mittlere quadratische Fehler (MSE)** ist definiert durch:

$$F(\vec{w}) = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{k=1}^N F(\vec{x}_k, \vec{w})$$


Der mittlere quadratische Fehler ist das am häufigsten verwendete Fehlermaß. Folgende Eigenschaften sind für das Backpropagation-Netz von Bedeutung:

- $F(\vec{w})$ existiert, da die Reihe konvergiert.
- $F(\vec{w})$ ist stetig und differenzierbar in \vec{w} .
- $F(\vec{w}) \geq 0$.

Minimierung des MSE durch Anpassung der Gewichte

Wird \vec{w} variiert, so lässt sich $F(\vec{w})$ für jedes \vec{w} bestimmen. Werden für alle möglichen Gewichtskombinationen $\vec{w} \in \mathbb{R}^q$ der $F(\vec{w})$ und mit W der Vektorraum aller \vec{w} bestimmt, so ergeben alle Werte zusammen die Fehlerverlaufskurve bezüglich W .

ABB. 18: FEHLERVERLAUFSKURVE I

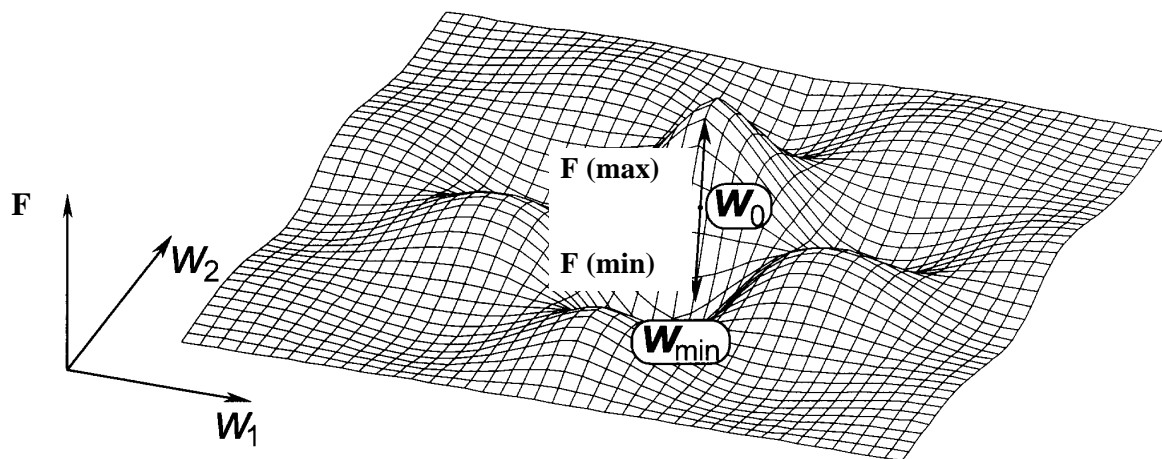


Quelle: Eigene Darstellung

Ziel der Gewichtsveränderungen ist es, eine Belegung \vec{w}_{\min} aller Gewichte des Netzes derart zu finden, dass F ein absolutes Minimum $F_{\min} > 0$ ist (vgl. Abb.18).

Bei der obigen Darstellung ist zu beachten, dass die einzelnen \vec{w} auf der W -Achse selbst mehrdimensional sind. Die obige Abbildung ist nur zweidimensional dargestellt und entsprechend vereinfacht. Genauer wird also durch F eine Oberfläche über dem Raum der möglichen Gewichtsvektoren ($\subset \mathbb{R}^q$) des Backpropagation-Netzes definiert (vgl. Abb. 19). $F(\vec{w})$ gibt die „Höhe“ dieser Fehleroberfläche in \vec{w} an.


ABB. 19: FEHLERFLÄCHE FÜR ZWEI GEWICHTSVERÄNDERUNGEN



Quelle: Eigene Darstellung

Zu einem gegebenen Gewichtsvektor \vec{w}' des Backpropagation-Netzes gehört ein bestimmter Punkt $(\vec{w}', F(\vec{w}'))$ auf der MSE-Oberfläche. Gesucht ist ein Verfahren, das \vec{w}' auf der \vec{W} -Achse so verschiebt, dass $(\vec{w}', F(\vec{w}'))$ in ein (möglichst globales) Minimum bewegt wird (vgl. Abb. 20).


ABB. 20: FEHLERVERLAUFSKURVE II



Quelle: Eigene Darstellung

Das Backpropagation-Verfahren beruht auf einem Gradientenabstiegsverfahren: Im Punkt \vec{w}' wird die "Tangente" der MSE-Oberfläche bestimmt und auf der Tangente um eine gewisse vorgegebene Länge abgestiegen (Abb. 21). Hierdurch erhält man den Gewichtsvektor \vec{w}'' , bestimmt wieder die Tangente und wiederholt das Verfahren.

ABB. 21: FEHLERVERLAUFKURVE III



Quelle: Eigene Darstellung

Richtung des Abstiegs

Da die einzelnen \vec{w} Vektoren q -dimensional sind, wird allgemein die Richtung des Abstieges definiert als (vgl. ZIMMERMANN, 1994, S. 41):

$$\nabla_{\vec{w}} F(\vec{w}) := \left(\frac{\partial F(\vec{w})}{\partial w_1}, \dots, \frac{\partial F(\vec{w})}{\partial w_q} \right)^T$$

Als Gradient bezeichnet man einen Richtungsvektor, der in seinen Komponenten der ersten Ableitung entspricht, aber als Spaltenvektor definiert ist. Die Transponierte eines Vektors oder einer Matrix wird durch einen hochgestellten Index T gekennzeichnet. Durch Verschiebung von \vec{w} in Richtung $-\nabla_{\vec{w}} F(\vec{w})$ kann man sich einem Minimum nähern. Hierzu wird ein Verfahren zur komponentenweisen Berechnung von $\nabla_{\vec{w}} F(\vec{w})$ benötigt.

Im folgenden sei $F_k(\vec{x}_k, \vec{w})$ abgekürzt mit $F_k(\vec{w})$. Es stellt sich nun die Frage nach der Berechnung von $-\nabla_{\vec{w}} F(\vec{w})$. Hierzu betrachten wir zunächst für ein $p \in \{1, \dots, q\}$ den

$$\text{Term } \frac{\partial F}{\partial w_p}.$$

Es gilt

$$\frac{\partial F_k(\bar{w})}{\partial w_p} = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{k=1}^N \frac{\partial F_k(\bar{w})}{\partial w_p}$$

Für w_p gibt es genau einen Index (h, i, j) , so dass $w_p = w_{h,i,j}$ ist. Mit $w_{h,i,j}$ wird das Gewicht für eine Verbindung zwischen $n_{h-1,i}$ und $n_{h,i}$ bezeichnet. Da $n_{h,i}$ das i -te Neuron in der h -ten Schicht bezeichnet; die konstanten Neuronen besitzen den Index $i = 0$. Die Ausgabe von $n_{h,i}$ wird entsprechend als $o_{h,i}$ gekennzeichnet.

Für Backpropagation-Netze wird net bezüglich $n_{h,i}$ folgendermaßen berechnet:

$$net = \sum_{j=0}^{\#(U_{h-1})} o_{h-1,j} w_{h,i,j}$$

wobei $\#(U_n)$ die Anzahl der nicht konstanten Neuronen in U_n ist.

Es besteht eine funktionale Abhängigkeit der F_k von $w_{h,i,j}$, da für die Ausgabe $o_{h,i}$, die den Fehler F_k beinhaltet, gilt

$$o_{h,i} = s(net_{h,i})$$

wobei s eine sigmoide Ausgabefunktion ist.

Aus diesem Grund muss für die weitere Berechnung die Kettenregel angewandt werden:

$$\frac{\partial F_k(\bar{w})}{\partial w_p} = \frac{\partial F_k(\bar{w})}{\partial w_{h,i,j}} = \frac{\partial F_k(\bar{w})}{\partial net_{h,i}} \times \frac{\partial net_{h,i}}{\partial w_{h,i,j}}$$

Kürzt man $\frac{\partial F_k(\bar{w})}{\partial net_{h,i}}$ mit $d_{h,i}^k$ ab, so ergibt sich

$$\frac{\partial F_k(\bar{w})}{\partial w_p} = d_{h,i}^k \frac{\partial}{\partial w_{h,i,j}} \left(\sum_{r=0}^{\#(U_{h-1})} o_{h-1,r}^k w_{h,i,r} \right) = d_{h,i}^k o_{h-1,j}^k,$$

da die Ableitungen

$$\frac{\mathcal{J}(o_{h-1,r}^k w_{h,i,r})}{\mathcal{J} w_{h,i,j}}$$

für $r \neq j$ Null bzw. für $r = j$ $o_{h-1,j}^k$ ergeben. Hierbei ist $o_{h-1,j}^k$ die Ausgabe des j -ten Neurons in der $(h-1)$ -ten Schicht während des k -ten Trainingsschrittes. Man erhält damit

$$\frac{\mathcal{J} F(\bar{w})}{\mathcal{J} w_p} = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{k=1}^N d_{h,i}^k o_{h-1,j}^k .$$

Es verbleibt noch die Berechnung von $d_{h,i}^k$.

$$d_{h,i}^k = \frac{\mathcal{J} F_k(\bar{w})}{\mathcal{J} net_{h,i}} .$$

Berechnung für zweilagige Netze

Für den Output-Layer ist die Berechnung einfach, weil die Soll-Outputs bekannt sind. Für den Hidden-Layer ergibt sich aber die Schwierigkeit, dass die Soll-Outputs vorher nicht bekannt sind. Deshalb muss das Fehlermaß für die Hidden-Neuronen aus dem Fehlermaß der Output-Neuronen berechnet werden (vgl. ZELL, 1994, S.109).

Für den Fall, dass h ein Output-Layer ist, gilt $o_{h,i} = net_{h,i}$, da hier die Ausgabefunktion die Identität ist. Es gilt

$$d_{h,i}^k = \frac{\mathcal{J} F_k(\bar{w})}{\mathcal{J} o_{h,i}}$$

bzw.

$$\frac{\mathcal{J} F_k(\bar{w})}{\mathcal{J} o_{h,i}} = \frac{\mathcal{J}}{\mathcal{J} o_{h,i}} \sum_{r=1}^{\#(U_{H-1})} (y_r^k - o_{h,r}^k)^2 = -2 (y_i^k - o_{h,i}^k)$$

Dabei ist y_i^k ist die i -te Komponente der korrekten Ausgabe.

Berechnung für drei- und mehrlagige Netze

Wenn die h -te Schicht nicht der Output-Layer ist, gilt, da F_k über $o_{h,i}$ funktional von $net_{h,i}$ abhängt:

$$d_{h,i}^k \equiv \frac{\mathcal{J} F_k(\vec{w})}{\mathcal{J} net_{h,i}} = \frac{\mathcal{J} F_k(\vec{w})}{\mathcal{J} o_{h,i}} \frac{\partial o_{h,i}}{\mathcal{J} net_{h,i}} = \frac{\mathcal{J} F_k(\vec{w})}{\mathcal{J} o_{h,i}} s'(net_{h,i}) .$$

Für $\frac{\mathcal{J} F_k}{\mathcal{J} o_{h,i}}$ ergibt sich

$$\frac{\mathcal{J} F_k}{\mathcal{J} o_{h,i}} = \sum_{r=1}^{\#(U_{h+1})} \frac{\mathcal{J} F_k}{\mathcal{J} net_{h+1,r}} \times \frac{\mathcal{J} net_{h+1,r}}{\mathcal{J} o_{h,i}}$$

da F_k über $net_{h+1,r}$ ($r=1, \dots, \#(U_{h+1})$) funktional von $o_{h,i}$ abhängt .

Damit erhält man für $d_{h,i}^k$

$$d_{h,i}^k = s'(net_{h,i}) \sum_{r=1}^{\#(U_{h+1})} d_{h+1,r}^k \cdot w_{h+1,r,i}$$

Aufgrund der obigen Berechnungen ergibt sich für den **Backpropagation-Algorithmus** die Formel (vgl. ZELL, 1994, S.110)

$$\boxed{\vec{w}^{neu} = \vec{w}^{alt} - h \tilde{N}_{\vec{w}} F(\vec{w})}$$

bzw. für die Veränderung eines einzelnen Gewichtes die Formel

$$\boxed{w_{h,i,j}^{neu} = w_{h,i,j}^{alt} - h \cdot \lim_{N \rightarrow \infty} \frac{1}{N} \cdot \sum_{k=1}^N d_{h,i}^k \cdot o_{h-1,j}^k}$$

mit $\partial_{hj}^k = \frac{\mathcal{J}}{\mathcal{J} o_{hj}} \sum_{r=1}^{\#(U_{h-1})} (y_r^k - o_{h,r}^k)^2$ falls h die Ausgangsschicht ist.

mit $d_{h,i}^k = s'(net_{h,i}) \sum_{r=1}^{\#(U_{h+1})} d_{h+1,r}^k \cdot w_{h+1,r,i}$ falls h nicht die Ausgangsschicht ist.

Diese Lernregel wird in Anlehnung an die Delta Lernregel als die *verallgemeinerte Delta Lernregel* bezeichnet. Der in der Lernregel auftretende Faktor $h > 0$ wird Lernrate genannt und steuert, um welchen Anteil von $-\nabla_{\vec{w}} F(\vec{w})$ der Vektor \vec{w} verschoben wird.

Anhand dieses Fehlermaßes $d_{h,i}^k$ kann die Wirkungsweise des Backpropagation-Verfahrens sehr gut nachvollzogen werden. Der Fehler der Hidden-Neuronen wird schrittweise rückschreitend unter Zuhilfenahme des aufsummierten Fehlers und dem Verbindungsgewicht zwischen den Hidden-Neuronen und dem nachfolgenden Neuron berechnet. Dieses Vorgehen gilt für alle NN, in denen die Backpropagation-Lernregel nicht nur bei dem Output-Neuron, sondern auch im Bereich der Hidden-Neuronen zur Anwendung kommen soll. Durch diese Vorgehensweise wird sichergestellt, dass mögliche Fehler nicht nur anhand des Output festgestellt werden können, sondern konkret zurück verfolgt werden können. Das erleichtert wiederum die Gestaltung des NN, weil hierdurch die Parametereinstellung verbessert werden kann.

Ablauf eines Backpropagation-Algorithmus

Das Lernen erfolgt bei den Backpropagation-Netzen durch überwachtes Lernen. Im Prinzip laufen alternierend die folgenden Schritte ab (vgl. NAUCK et al., 1996, S.78):

1. In diesem Schritt wird dem Netz ein beliebiger Eingabevektor \bar{x} aus der Trainingsmenge eingegeben. Ist $\#(U_0) = n$ so ist $\bar{x} = (x_1, \dots, x_n)$. In der Schicht U_1 wird bei jedem Neuron zunächst die Aktivierung über die Aktivierungsfunktion berechnet und danach mittels der Ausgabefunktion die Ausgabe ermittelt. Die Ausgaben der Schicht U_1 bilden die Eingabe für die Schicht U_2 usw. Die Daten durchlaufen somit schichtweise das Netz (von links nach rechts) bis der Output-Layer einen Vektor $\bar{o} = (o_1, \dots, o_m)^T$ mit $m = \#(U_{H-1})$ liefert.
2. Die vom Netz gelieferte Ausgabe \bar{o} wird mit der korrekten Ausgabe \bar{o}' verglichen. Liegt der Fehler unterhalb einer vorgegebenen Güteschwelle, so wird das Training abgebrochen und ggf. eine spezielle Testphase eingeleitet, andernfalls erfolgt die Selbstmodifikation durch Schritt 3.
3. Es werden sukzessiv die Gewichte, beginnend mit den Gewichten des Output-Layers U_{H-1} , (d.h. die Gewichte an den Verbindungen von den Neuronen der Schicht U_{H-2} nach U_{H-1}) nach der vorgegebenen Lernregel verändert.

Zunächst wird die erwartete (korrekte) Ausgabe \bar{o}' (bzw. die Differenz $|\bar{o} - \bar{o}'|$) benutzt, um die Gewichte von U_{H-1} zu ändern. Die neuen Gewichte von U_{H-1} (bzw. deren Änderungen) dienen als Basis für die Änderung der Gewichte der Schicht U_{H-2} usw. Die Fehlerkorrektur (Änderung der Gewichte) erfolgt also schichtweise von rechts nach links, bis zum Schluss alle Gewichte der Schicht U_1 verändert sind.

Die Anwendung der Backpropagation-Lernregel kann deswegen in zwei Phasen aufgeteilt werden. Während der ersten Phase wird dem NN der Input präsentiert und vorwärts durch das Netz propagiert, um so zum Output zu gelangen. Danach wird dieser mit dem gewünschten Soll-Output verglichen. Da der Ist-Output in der Regel hiervon abweicht, wird diese Abweichung als Fehlermaß zwischen diesen beiden Output berechnet. In der zweiten Phase wird dieses Fehlermaß dazu benutzt, die

Verbindungsgewichte der vorgelagerten Neuronen zu verändern. Dies ermöglicht die rekursive Berechnung des Fehlermaßes wie oben angegeben.

Der Backpropagation-Algorithmus eignet sich als Lernverfahren für ein MLP-Netz. Dementsprechend kann er als Klassifikator von nichtlinearen Beziehungen, wie sie bei der Kennzahlen der Jahresabschlussanalyse vorliegen, eingesetzt werden.

3.4.6.3.1 Probleme beim Backpropagation-Lernverfahren

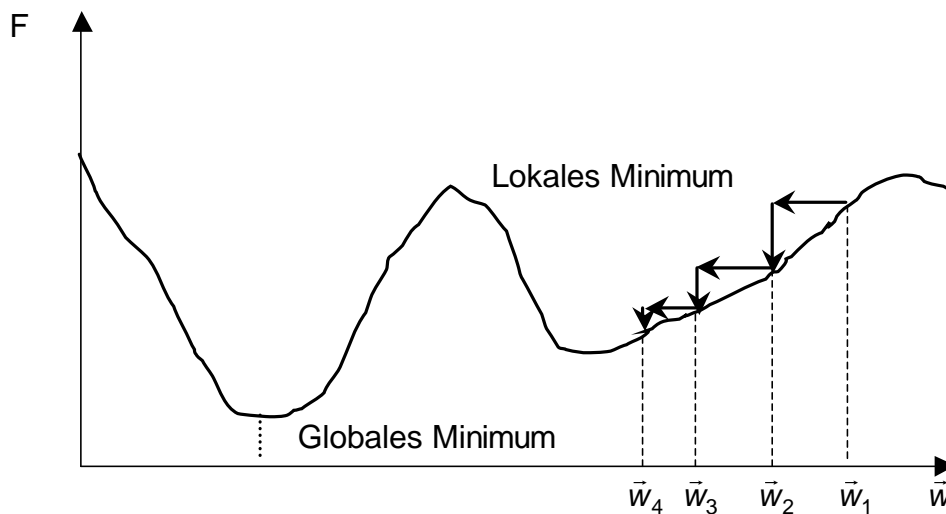
Die Grundidee des Backpropagation-Verfahrens - ein Gradientenabstieg - ist naheliegend und relativ einfach. Dieses Verfahren beinhaltet aber eine Reihe von Problemen, die im wesentlichen darauf beruhen, dass der weitere Fortschritt der Fehlerminimierung durch die Kenntnis der aktuellen lokalen Umgebung (Gradient) beeinflusst wird. Die wesentlichsten Probleme sollen im folgenden kurz erläutert werden (ZELL, 1994, S.110):

Symmetry Breaking

Die Initialisierung aller Gewichte w erfolgt durch kleine, zufällige Werte (z.B. zwischen -0,1 und +0,1). Der Grund hierfür ist die entstehende Symmetrie in den Hidden-Layern. Bei einem Anfangswert von Null werden alle Elemente eines Hidden-Layers, die die gleichen Input-Elemente haben, mit dem Input der vorhergehenden Schicht jeweils mit denselben Gewichten w multipliziert und haben die gleiche Aktivität. Da hierdurch die Fehler von der nachgeschalteten Schicht für alle Elemente mit der gleichen Aktivität identisch sind, berechnen sie genau die gleichen Gewichtsveränderungen Δw . Jedes dieser Elemente würde dadurch zu den anderen Elementen identische Gewichte aufweisen. So kann ein Problem, das unterschiedliche Gewichte verlangt, nicht trainiert werden.

Lokale Minima

Ein generelles Problem aller Gradientenverfahren besteht darin, dass sie ein lokales Minimum der Fehleroberfläche nicht überwinden können und dadurch nicht das globale (optimale) Minimum erreichen, d.h. das Gradientenabstiegsverfahren endet häufig in einem lokalen Minimum.

ABB. 22: LOKALES MINIMUM



Quelle: Eigene Darstellung

Es ist ein prinzipielles Problem der NN, dass die Fehleroberfläche mit wachsender Dimension des Netzes (d.h. mit wachsender Anzahl von Verbindungen) immer stärker zerklüftet ist und somit die Wahrscheinlichkeit, in einem lokalen anstelle des globalen Minimums zu landen, mit wachsender Dimension des Netzes größer wird.

Wenn die Schrittweite der Lernrate h nicht zu groß gewählt wird und mehrere verschiedene Initialisierungen der Gewichte ausprobiert werden, zeigt die Erfahrung, dass hierdurch in der Regel ein Minimum erreicht wird, welches für die konkrete Anwendung akzeptabel ist.

Flache Plateaus

Die Größe der Gewichtsänderung hängt bei Gradientenverfahren von dem Betrag des Gradienten ab. In flachen Plateaus stagniert daher das Backpropagation-Verfahren.

ABB. 23: FLACHES PLATEAU


Quelle: Eigene Darstellung


In einem derartigen Bereich werden besonders viele Iterationsschritte benötigt. Im Extremfall ist der Gradient der Nullvektor (Maxima) und es findet überhaupt keine Gewichtsveränderung mehr statt.

Eine zusätzliche Problematik ergibt sich dadurch, dass das Verhalten in einem flachen Niveau dem des Erreichens eines Minimums entspricht, so dass zunächst nicht erkannt werden kann, um welche Situation es sich handelt.

Oszillation

In steilen Schluchten der Fehlerfläche kann das Lernverfahren oszillieren. Dies geschieht, wenn die Schrittlänge am Rande einer Schlucht so groß ist, dass durch die Gewichtsänderung ein Sprung auf die gegenüberliegende Seite der Schlucht erfolgt. Ist die Schlucht dort genauso steil, bewirkt dies einen Sprung zurück zum Ausgangspunkt, da der Gradient jetzt den gleichen Betrag, aber das umgekehrte Vorzeichen besitzt.


ABB. 24: DIREKTES OSZILLIEREN



Quelle: Eigene Darstellung

Dieser Effekt tritt vor allem bei relativ steilen Schluchten der Fehleroberfläche auf. Ferner kann neben dem direkten Oszillieren auch ein indirektes Oszillieren auftreten.

ABB. 25: INDIREKTES OSZILLIEREN




Quelle: Eigene Darstellung

Verlassen guter Minima

Liegt das erstrebenswerte globale Minimum in einem steilen Tal, kann die Schrittlänge so groß sein, dass die Gewichtsänderung aus der Umgebung des globalen Minimums heraus und in die Umgebung eines suboptimalen Minimums hineinführt.

ABB. 26: VERLASSEN GUTER MINIMA



Quelle: Eigene Darstellung

3.4.6.3.2 Möglichkeiten zur Behebung der Problematiken

Den oben aufgezeigten prinzipiellen Problemen, die bei der Anwendung des Backpropagation-Verfahrens auftreten können, kann durch verschiedene Maßnahmen begegnet werden:

Die Wahl der Schrittweite der Lernrate h ist entscheidend für das Verhalten des *Backpropagation-Algorithmus*. Wird nach einer vorgegebenen Trainingszeit keine befriedigende Lerngüte erreicht, so empfiehlt es sich, die Lernrate h zu ändern. Generell bewirkt eine große Lernrate h starke Sprünge auf der Fehleroberfläche und erhöht somit das Risiko, ein globales Minimum in einem engen Tal zu überspringen. Zu kleine Werte der Lernrate h bewirken einen spürbar höheren Zeitaufwand während des Trainings, der in einem flachen Bereich inakzeptabel hoch werden kann. Da der optimale Wert der Lernrate h von vielen Faktoren, wie dem Problem der Wahl der Trainingsdaten, der Größe und Topologie des Netzes abhängt, kann keine generelle Empfehlung zur Wahl der Lernrate h gegeben werden.

Eine "unglückliche" Initialisierung der Startgewichte kann dazu führen, dass das Verfahren in einem kritischen Bereich der Fehleroberfläche (z.B. einem flachen Plateau) startet. Es kann daher sinnvoll sein, vor einer Änderung der Lernrate zunächst die Lernphase mit einer geänderten Initialisierung der Startgewichte zu wiederholen.

Um den Problemen des *Backpropagation-Verfahrens* zu begegnen, wurden von verschiedenen Autoren Modifikationen des Verfahrens entwickelt. Fast allen dieser Modifikationen ist gemein, dass sie auf Heuristiken beruhen. Sie bewirken daher in den meisten Fällen eine spürbare Beschleunigung des Konvergenzverhaltens. Jedoch lassen sich stets Fälle konstruieren, bei denen die Annahmen der Heuristiken nicht gegeben sind, so dass hier sogar eine Verschlechterung gegenüber dem klassischen *Backpropagation-Verfahren* eintritt. Im folgenden werden einige der weitverbreitetsten Modifikationen kurz beschrieben.

Momentum-Term

Dieses Verfahren wurde erstmals von RUMELHART, HINTON und WILLIAMS (1986) beschrieben. Die Idee des *Momentum-Term* ist eine Erhöhung der Schrittweite der Lernrate h auf flachen Niveaus und eine Reduzierung der Lernrate h bei Tälern. Hierzu müssen die jeweiligen Situationen erkannt werden. Dies geschieht dadurch, dass die in der Vergangenheit durchgeführten Gewichtsveränderungen einen Einfluss auf die aktuelle Gewichtsveränderung haben. Die zugrundeliegende Heuristik unterstellt, dass flache Plateaus dadurch gekennzeichnet sind, dass das Vorzeichen des Gradienten in aufeinander folgenden Schritten unverändert bleibt, während ein Vorzeichenwechsel ein Indiz für eine Senke (Schlucht) ist.

Dementsprechend wird im Schritt t jedes Gewicht $w_i(t)$ des Netzes nach folgender Vorschrift modifiziert:

$$\begin{aligned} w_i(t+1) &= w_i(t) + \Delta w_i(t) \\ \Delta w_i(t) &= -(1-a)h \frac{\partial F(t)}{\partial w_i(t)} + a \Delta w_i(t-1) \\ &= -(1-a)h \sum_{j=0}^t a^j \frac{\partial F(t-j)}{\partial w_i(t-j)}, \end{aligned}$$

dabei ist F das MSE-Fehlermaß, $a \in [0,1[$ der sogenannte *Momentum-Term* und $h > 0$ die Lernrate.

Der Term $\Delta w_i(t-1)$ gibt an, wie das Gewicht w_i bei der letzten Veränderung modifiziert wurde. Durch Addition von $a \Delta w_i \in [0,1[$ wird dem Gradientenabstiegsverfahren ein Trägheitsmoment verliehen.

Setzt man $a = 0$, so ist die obige Vorschrift wieder identisch mit der klassischen verallgemeinerten Delta-Lernregel.

Der *Momentum-Term* a steuert das Verhältnis der aktuell berechneten Ableitung von F für w_i bei der Bestimmung von $w_i(t+1)$. Dabei ist $\Delta w_i(t)$ im wesentlichen die exponentiell gewichtete Summe aller bisher für w_i berechneten Ableitungen. Der

Einfluss einer solchen Ableitung ist umso kleiner, je "älter" sie ist, da wegen $a \in [0,1[$ der Wert a^j mit steigendem j kleiner wird.

Haben (zeitlich) aufeinanderfolgende Ableitungen gleiche Vorzeichen, wächst die Summe (und w_i wird stärker modifiziert), ansonsten bleibt sie klein (und w_i wird weniger stark modifiziert). Hierbei wird zur Vereinfachung unterstellt, dass alle Gewichte innerhalb des Netzes fortlaufend über den Index i durchnummeriert sind.

Der Momentum-Term hat zwei Schwächen:

1. Der Trägheitsmoment wirkt sich auf flachen Gebieten der Fehleroberfläche sehr vorteilhaft auf die Lerngeschwindigkeit des Netzes aus. Die Summe kann aber eine obere Schranke besitzen (z.B. wenn alle Ableitungen konstant gleich sind). Damit ist auch die größtmögliche Gewichtsänderung beschränkt, was in flachen Gebieten der Fehleroberfläche nicht unbedingt erwünscht ist.
2. Die Summe ab $j = 1$ kann ein anderes Vorzeichen besitzen als der Summand für $j = 0$ (die momentane Ableitung); im Extremfall ist sie sogar betragsmäßig größer. Das Verfahren verschiebt dann \bar{w} in die Richtung des Gradienten, vergrößert also den Fehler des Netzes. Aus diesem Grund kann für das Verfahren keine Konvergenz garantiert werden.

Wegen des zweiten Problems kann bei dem *Momentum-Term* nicht mehr absolut von einem "Gradientenabstiegsverfahren" ausgegangen werden.

Durch die Wahl von unterschiedlichen Werten für a kann das Verhalten des Verfahrens stark beeinflusst werden. Typischerweise wird a nahe 0,9 gewählt, um den Vorteil des Trägheitsmomentes auf flachen Gebieten ausnutzen zu können. In stark gekrümmten Gebieten versagt das Verfahren jedoch schnell, wenn a zu groß ist. Es wäre also wünschenswert, wenn sich der Wert des *Momentum-Terms* verändern und an die Krümmungseigenschaften der Fehleroberfläche anpassen könnte. Erst durch Experimente kann für ein gegebenes Problem das am besten geeignete a bestimmt werden.

Weight Decay

Diese Modifikation geht auf PAUL WERBOS zurück, der in seiner Dissertation 1974 als erster das Backpropagation-Lernverfahren beschrieben hat. Die Motivation für die Lernregel mit Gewichtsabnahme (weight decay) ist folgende:

Es ist neurobiologisch unplausibel, zu große Gewichte zuzulassen. Außerdem wird durch große Gewichte die Fehlerfläche steiler und zerklüfteter, wodurch die Häufigkeit von Oszillationen und unkontrollierten Sprüngen auf der Fehlerfläche beim Lernen zunimmt. Daher leitete WERBOS (1974) die Forderung nach einem kleinen Betrag der Gewichte bei gleichzeitiger Annäherung an die Zielvorgaben der Trainingsmenge ab.

Wird diese Forderung als Term in die Fehlerfunktion aufgenommen, so führt das zu folgender Fehlerfunktion:

$$F^{neu} = F + \frac{d}{2} \sum_i w_i^2$$

Der zweite Summand "bestraft" zu große Gewichte. Durch Bildung der neuen partiellen Ableitung nach der Formel

$$\frac{\partial F^{neu}}{\partial w_i} = \frac{\partial F}{\partial w_i} + d \cdot w_i$$

ergibt sich eine Gewichtsmodifikationsregel, die gleichzeitig die Gewichte minimiert (weight decay):

$$\Delta w_i(t) = \eta \cdot \frac{\partial F(t)}{\partial w_i(t)} - d \cdot w_i(t-1) .$$

Dabei liegen die Werte von d im allgemeinen im Bereich von 0,005 bis 0,03. Bei der Verwendung dieses Parameters ist Vorsicht geboten, weil zu große Werte von d leicht dazu führen, dass das Gewicht im Netz permanent als zu gering eingeschätzt wird. Weitere Vorteile von kleinen Werten für d liegen vor allem in einer besseren Generalisierungsleistung des Netzwerks und darin, dass die Initialisierung der Gewichte weniger wichtig wird.


Mit Hilfe von *Momentum-Verfahren* und *Weight-Decay-Verfahren* ist man in der Lage die Probleme, die bei dem Backpropagation-Algorithmus auftreten, soweit zu beheben, dass dieser bei einer Klassifizierung trotzdem zu einem guten Ergebnis gelangt.

3.4.7 Backpropagation und statistische Funktionsanpassung

Um die Funktionsweise und die Einordnung der NN im Verhältnis zur statistischen Regression besser zu verstehen, wird der theoretische Hintergrund näher erläutert. Backpropagation-Netze werden verwendet, wenn bestimmte Eingabewerte auf bestimmte Ausgabewerte abgebildet werden sollen. Insofern können Backpropagation-Netze einfach als Funktionen aufgefasst werden. Das Lernproblem besteht darin, jene Funktion zu finden, die am genauesten die Trainingsausgabewerte den entsprechenden Trainingseingabewerten zuordnet. Durch Variation der Netzgewichte verändert sich die durch das Netz berechnete Funktion. Optimale Gewichte sind diejenigen, welche die beste Anpassung der Netzausgabe an die vorgegebenen Ausgabewerte vornehmen. Dabei spielen zwei entgegengesetzte Motivationen eine Rolle. Einerseits soll das Netz nach der Lernphase die Trainingseingabewerte möglichst genau abbilden, andererseits wird aber erwartet, dass das Netz verallgemeinern kann, d.h. es muss für unbekannte Eingabewerte eine Ausgabe produzieren, die eine Art Interpolation der Ausgaben aller bekannten

Eingaben ist. Genauigkeit der Resultate für die vorgegebene Trainingsmenge und gute Verallgemeinerungsfähigkeit sind jedoch oft entgegengesetzte Ziele.

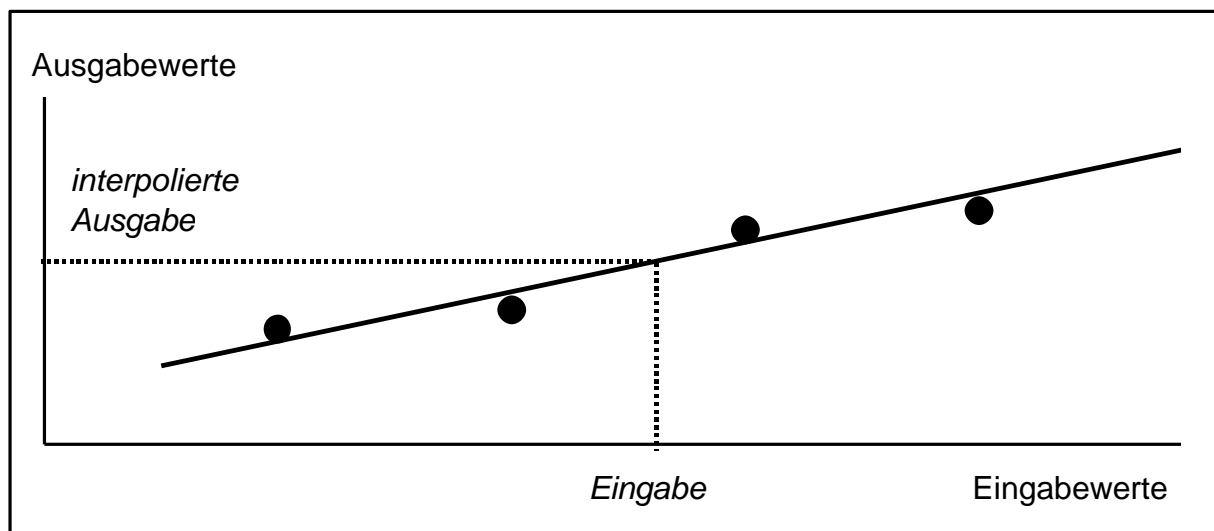
ABB. 27: BACKPROPAGATION-NETZE ALS FUNKTIONEN



Quelle: ROJAS, 1996, S.176

Durch die Abb. 27 wird veranschaulicht, wie ein Netz den Eingaberaum in einen Ausgaberaum abbildet. Die schwarzen Punkte im Eingaberaum stellen die Trainingseingaben dar, die auf die Trainingsausgabe abgebildet werden sollen. Es ist aber auch erwünscht, dass die Nachbarschaften der Trainingseinheiten auf Nachbarschaften der Trainingsausgaben abgebildet werden. Eine für das Netz unbekannte Eingabe, die dicht an einer trainierten Eingabe liegt, soll in der Nähe der trainierten Ausgabe abgebildet werden. Offensichtlich soll das Netz eine stetige Abbildung des Eingaberaums in den Ausgaberaum berechnen. Wenn Integrations- und Aktivierungsfunktion des Netzes stetig sind, ist diese Forderung automatisch erfüllt.

ABB. 28: LINEARE ANNÄHERUNG AN DIE TRAININGSMENGE



Quelle: ROJAS, 1996, S.176

Die Abb. 28 stellt diese Problematik aus einem anderen Blickwinkel dar. Gesucht wird eine Funktion, die die Trainingsausgaben anhand der Trainingseingaben berechnen kann. Die Punkte stellen in diesem Fall die Trainingsdaten dar. Wenn es sich bei der gesuchten Funktion um eine lineare Funktion handelt, ist, wie in der Abb. 28 gezeigt, die Gerade eine gute Annäherung an die durch die Punkte dargestellten Paare von Ein- und Ausgabewerten. Eingaben, die nicht zur Trainingsmenge gehören, erzeugen als Ausgabe eine Interpolation der trainierten Punkte.

Statt einer Geraden kann auch eine andere Art von Funktion verwendet werden, die die Trainingsdaten exakt reproduziert. Besteht die Trainingsmenge aus empirischen Daten, so ist die Wahrscheinlichkeit von verrauschten Daten hoch. In diesem Fall hat es keinen Zweck, die Trainingsdaten exakt zu reproduzieren. Eine lineare Annäherung liefert dann eine bessere Anpassung an die Wirklichkeit des Problems als die exakte Anpassung.

Annäherung versus Verallgemeinerung

Das Beispiel zeigt die zwei entgegengesetzten Ziele der Funktionsanpassung: Minimierung des Trainingsfehlers versus Maximierung der Interpolationsfähigkeit für unbekannte Eingaben. Die Genauigkeit eines Netzes bei der Berechnung der Trainingswerte hängt davon ab, wie viele Freiheitsgrade (d.h. wieviele Gewichte) im Netz vorhanden sind und wie kohärent die Trainingsmenge ist. Die Anzahl der Freiheitsgrade eines Netzes bestimmt die Anpassungsfähigkeit der vom Netz berechneten Funktion an die Trainingsmenge. Die Erhöhung der Anzahl der Gewichte bewirkt somit die Herabsetzung des Trainingsfehlers, aber eine mögliche Vergrößerung der Interpolationsfehlers des Netzes für unbekannte Eingaben. Bei der Reduzierung der Anzahl der Gewichte tritt der umgekehrte Effekt auf.

Deshalb gibt es kein Patentrezept für die Bestimmung der optimalen Parameteranzahl eines Netzes. Sie hängt von dem jeweiligen Problem ab. Die Resultate werden verbessert, je mehr Fachwissen über die funktionale Beziehung zwischen Eingabe- und Ausgaberaum in die Auswahl des NN und deren Parametereinstellung einfließen.

Backpropagation-Algorithmus als statistische Methode

Die Art der Anpassung von Funktionen an vorgegebene empirische Wertepaare gehört in den Bereich der statistischen Methoden. Der Backpropagation-Algorithmus ist deswegen streng genommen nur eine statistische Methode der Funktionsanpassung (ROJAS, 1996, S.177).

ROJAS (1996) hat gezeigt, dass mit den NN die gleichen Funktionen gebildet werden können wie mit einer linearen Regression. Des weiteren besitzen mehrschichtige NN die Fähigkeit, komplexe Funktionen zu berechnen, was durch die Kombination der

Faltungen der einzelnen sigmoiden Ausgaben mehrerer Neuronen möglich ist. Hierdurch können auch nichtlineare Regressionen nachgebildet werden.

Wird der Backpropagation-Algorithmus zur Bestimmung der Parameter eines komplexen Netzes verwendet, dann wird in der Regel eine komplexe Funktion berechnet, die nur anhand von Beobachtungswerten bekannt ist. Die Anzahl der Freiheitsgrade eines Backpropagation-Netzes hängt von der Anzahl der Gewichte im Netz ab und diese wiederum vor allem von der Anzahl der Neuronen in den Hidden-Layer. Die Anzahl der Ausgabeneuronen ist durch das Problem fest vorgegeben. Wieviele Neuronen im NN enthalten sein müssen, um ein bestimmtes Problem lösen zu können, hängt von dem optimalen Grad eines Anpassungspolynoms ab und kann nicht unabhängig vom Problem selbst beantwortet werden. Im Idealfall sollte die Anpassungsfunktion nicht mehr Freiheitsgrade als das Problem selbst besitzen. Das Wissen über die genaue Art funktionaler Beziehungen zwischen den Variablen ist problemspezifisch. Wenn zu viele Freiheitsgrade für die Anpassung benutzt werden, d.h. die Anzahl der Neuronen zu hoch ist, dann nimmt der Fehler für die Trainingsdaten ab, aber der Fehler für die Testdaten wird größer und somit verringert sich die Generalisierungsfähigkeit des NN.

Backpropagation-Netze mit mehreren Schichten (MLP) sind das populärste Modell für die Lösung von realen Problemen. Es soll anhand einiger weniger empirischer Daten ein Netz aufgebaut werden, das die zugrundeliegende Generalisierungsfunktion simulieren kann. In vielen Fällen sind die empirischen Abhängigkeiten der Modellvariablen entweder von vornherein unbekannt, oder sie verändern sich im Laufe der Zeit. Backpropagation kann statistische Regelmäßigkeiten entdecken und ausnutzen und die Netzparameter auch (durch permanentes Lernen) verändern.

Es ist trotzdem eine Illusion zu glauben, dass das Backpropagation-Verfahren genaueres Wissen über die Probleme selbst ersetzen kann. Algorithmus und Netz können nur dann zutreffende statistische Prognosen treffen, wenn das Netz die notwendige Information erhält. Für das Backpropagation-Verfahren gilt, wie auch für die Statistik im allgemeinen, dass die besten Methoden unzureichende oder inkohärente Daten nicht in zuverlässige Ergebnisse verwandeln können.

3.4.8 Der LVQ als weiteren Lernalgorithmus für Klassifizierungsprobleme

Der Backpropagation-Algorithmus braucht teilweise lange Lernphasen und bietet fast keine Interpretationsmöglichkeiten der Ergebnisse (KÖHLE, 1990, S.128ff.). Aus diesem Grund sind andere Lernverfahren entwickelt worden, die diese Probleme nicht aufweisen.

Angesichts der Vielzahl der bekannten NN-Typen (vgl. ZELL, 1994) soll in Abhängigkeit der Problemdefinition eine Auswahl derjenigen NN getroffen werden, die

prinzipiell für die Aufgabenstellung der Jahresabschlussanalysen geeignet erscheint. Ein mögliches Verfahren ist das Verfahren der lernenden Vektorquantifizierung.

Learning Vector Quantization (LVQ)

Ein vergleichsweise besonders einfacher und schneller Lernalgorithmus ist der Learning Vector Quantization (LVQ). Durch den schnellen Trainingsalgorithmus liegt der Zeitaufwand für die Erstellung eines LVQ-Netzwerkes nur bei einem Bruchteil von anderen Modellen. Dieser Ansatz bietet eine Reihe von weiteren Vorteilen. Durch die Repräsentation einzelner Klassen durch mehrere Hidden-Neuronen ist der LVQ in der Lage, nichtlineare trennfähige Klassifizierungsprobleme zu bewältigen. In Verbindung mit der einfachen Klassifizierung unbekannter Instanzen über ein Distanzmaß gewährleistet dieser Ansatz selbst bei verrauschten Datenmaterial beziehungsweise sich überschneidenden Klassen eine gute Generalisierungsfähigkeit (KERLING und PODDIG, 1994, S.447).

Aufgrund dieser Vorteile eines LVQ Lernalgorithmus soll dieser als Alternative zum Backpropagation-Algorithmus beschrieben und verwendet werden. Das LVQ ist ein Verfahren zur Mustererkennung. Es versucht, einen Merkmalsvektor in seiner Gesamtheit als Merkmalsausprägungsmuster zu erkennen und zu klassifizieren. Des weiteren bietet sich die Interpretation der Hidden-Neuronen als Prototypen der einzelnen Klassen als eine Erklärungskomponente an. Durch den Vergleich eines anliegenden Merkmalsvektors mit dem aktiven Prototypen eines LVQ kann das Klassifikationsergebnis des LVQ nachvollzogen und erklärt werden. Dies fördert die Akzeptanz potentieller Anwender (KERLING und PODDIG, 1994, S.447). Bei dem LVQ handelt es sich um ein einschichtiges NN, dessen Ursprung in dem von *TEUVO KOHONEN* entwickelten Modell der selbstorganisierten Karten liegt (ZELL, 1994, S.171). Hieraus wurde später der Ansatz der lernenden Vektorquantifizierung LVQ weiterentwickelt. Dieser Algorithmus gehört zur Familie der Assoziativspeicher-Modelle. Diesen NN-Modellen ist gemeinsam, dass sie der Speicherung von Mustern und nicht deren Abbildungen dienen.

Der LVQ ist ein überwachtetes Lernverfahren, bei dem zu jedem Eingabevektor bekannt sein muss, zu welcher Klasse er gehört. Dieser vollkommen andere Ansatz zur Trennung von Merkmalen lässt dieses Lernverfahren zur Trennung von Jahresabschlüssen in unterschiedlichen Klassen interessant erscheinen.

Da der zweilagige LVQ bei der Klassifizierung von Jahresabschlüssen Schwächen aufweist, ist dieser auf ein dreilagiges Netzwerk erweitert worden (PYTLIK, 1994, S.191f.). Der LVQ besteht aus einem Input-Layer, einem variablen Hidden-Layer und einem Output-Layer. Der Hidden-Layer wird automatisch während des Trainings festgelegt. Die Begrenzung der Anzahl ist durch den Benutzer möglich. Der Input-Layer dient während der Testphase zum Anlegen von Merkmalsvektoren \vec{x} der

Instanzen einer Klasse. Die Input- und Hidden-Layer sind vollständig miteinander vernetzt. Die Hidden-Layer sind aber nur jeweils mit einem Output-Layer verbunden. Hidden-Layer, die während der Trainingsphase des LVQ neu erzeugt werden, müssen nach diesen Kriterien mit dem Input- und Output-Layer verbunden werden.

Ein LVQ soll durch assoziatives Lernen trainiert werden, verschiedene Klassen zu unterscheiden. Jede Instanz einer Klasse hat bestimmte klassenspezifische Merkmale, und jede Klasse besteht aus mehreren solcher Instanzen. Bei der Betrachtung der n Merkmale einer Instanz als Vektor, kann dieser Vektor $\vec{x} \in \mathbb{R}^n$ als Punkt in einem n -dimensionalen Raum interpretiert werden und diese Instanz identifizieren. Durch mehrere solcher Instanzen einer Klasse wird eine Punktwolke gebildet beziehungsweise der Merkmalsraum der Klasse in diesem n -dimensionalen Raum. Die k -Hidden-Neuronen sind über ihre Gewichte mit allen n Input-Neuronen vernetzt. Hierdurch können sie über einen n -dimensionalen Gewichtsvektor $\vec{w}_i \in \mathbb{R}^n$ ($1 \leq i \leq k$) ebenfalls als Punkt in diesem imaginären Raum interpretiert werden. Ziel dieses Lernverfahrens ist es, die k -Hidden-Neuronen h_i über ihre n -dimensionalen Gewichtsvektoren \vec{w}_i so in die Punktwolke der einzelnen Klassen zu verschieben, dass sie diese möglichst gut repräsentiert. Nach einer Lernphase können die k -Hidden-Neuronen über ihre Gewichtsvektoren $w_i \in \mathbb{R}^n$ als Prototypen der einzelnen Klassen interpretiert werden.

Beim überwachten Lernverfahren des LVQ muss die Zugehörigkeit der Merkmalsvektoren \vec{x} zu ihren jeweiligen Klassen C_x bekannt sein. Die k -Hidden-Neuronen werden entweder vor dem Trainingsbeginn statisch oder während der Trainingsphase dynamisch allokiert und initialisiert.

Bei dem LVQ handelt es sich um ein "Nearest-Neighbour-Verfahren" in der "winner takes it all"-Version. Das bedeutet, dass nur das Hidden-Neuron h_c seinen Gewichtsvektor \vec{w}_c verändern darf, das die kürzeste Entfernung zum anliegenden Merkmalsvektor \vec{x} hat und ihm somit am ähnlichsten ist. In der Trainingsphase werden die Datensätze der Trainingsmenge mehrmals in Zyklen abgearbeitet. Wird ein Merkmalsvektor \vec{x} an den Input-Layer angelegt, so muss überprüft werden, ob bereits ein oder mehrere Hidden-Neuronen existieren. Wenn dies nicht der Fall ist, wird ein Hidden-Neuron h_n erzeugt. Als Gewichtsvektor \vec{w}_c dieses neuen Hidden-Neuronen wird der anliegende Merkmalsvektor \vec{x} verwendet. Die Klassenzugehörigkeit des anliegenden Merkmalsvektor \vec{x} dient zur Verbindung des neuen Hidden-Neurons h_n zu dem entsprechenden Output-Neuron.

Existieren ein oder mehrere Hidden-Neuronen, dann muss das Hidden-Neuron ermittelt werden, das den geringsten Abstand zum anliegenden Merkmalsvektor hat.

Für diese Aufgabe wird normalerweise die Abstandsmessung "Euklidische Distanzmaß d" verwendet (KOHONEN, 1986, S.3).

$$d_i = \|\vec{x} - \vec{w}_i\| = \sqrt{\sum_{j=1}^n (\vec{x}_j - \vec{w}_{ij})^2}$$

d_i ist der Abstand d zwischen den anliegenden Merkmalsvektor \vec{x} und dem i -ten Hidden-Neuronen h_i , \vec{w}_{ij} das j -te Element des Gewichtsvektors \vec{w}_i und \vec{x}_j das j -te Element des Merkmals \vec{x} . Das Hidden-Neuron h_i mit d_{\min} wird "winner" h_c genannt und darf seine Gewichte verändern. Hierbei muss die Klasse C_x des Merkmalsvektors \vec{x} gleich der Klasse C_c des winners h_c sein (vgl. KOHONEN, 1986, S.7).

Folgende neue Gewichte ergeben sich hieraus:

$$\vec{w}_i(t+1) = \vec{w}_i(t) \text{ für } i \neq c;$$


$$\vec{w}_c(t+1) = \vec{w}_c(t) + a(t) * (\vec{x} - \vec{w}_c(t)), \text{ falls } C_x = C_c;$$

$$\vec{w}_c(t+1) = \vec{w}_c(t) - a(t) * (\vec{x} - \vec{w}_c(t)), \text{ falls } C_x \neq C_c$$

Falls die maximale Anzahl der Hidden-Neuronen bisher nicht erreicht worden ist, wird ein neues Hidden-Neuron nach obigem Prinzip generiert.

Bei diesen Formeln ist t ein ganzzahliger Zeitindex, $\vec{w}_c(t)$ der ursprüngliche Gewichtsvektor des winners h_c , $\vec{w}_c(t+1)$ dessen neuer Gewichtsvektor, \vec{x} der anliegende Merkmalsvektor und $a(t)$ eine zeitabhängige Lernrate mit $0 \leq a(t) \leq 1$.

Nach der Trainingsphase ist das Netzwerk in der Lage, den "Nearest-Neighbour" \vec{w}_c eines unbekanntes Merkmals \vec{x} aus den k Hidden-Neuronen zu ermitteln. Dies geschieht wieder mit Hilfe des Euklidischen Distanzmaßes d . Auf diese Weise kann der LVQ einen unbekanntes Merkmalsvektor über den Prototypen \vec{w}_c einer bestimmten Klasse zuordnen.

ABB. 29: AUFBAU EINES LVQ

Quelle: in Anlehnung an KERLING und PODDIG, 1994, S. 444

Die Klassifizierungsergebnisse in der Praxis sind aber teilweise enttäuschend (KERLING und PODDIG, 1994, S.451). Aus diesem Grund haben diese Verfahren es bisher nicht zur selben Popularität gebracht wie das Backpropagation-Verfahren.

3.4.9 Übertraining und Generalisierung Neuronaler Netze

Beim Entwickeln eines NN existieren die entgegengesetzten Ziele: Minimierung des Trainingsfehlers versus der Maximierung der Generalisierung. Es gibt zwar kein Patentrezept für die optimale Dauer des Lernprozesses, aber man kann diese wichtige Entscheidung nicht dem Zufall überlassen. Man muss zumindest annäherungsweise die Lerndauer bestimmen, bei der beide Ziele optimal erfüllt werden.


Vom ökonomischen Standpunkt aus gesehen, besteht die Aufgabe der NN darin, aus verrauschten Daten hochdimensionale nichtlineare Strukturen herauszukristallisieren. Dafür stehen im Verhältnis zur Komplexität der Aufgabenstellung meist nur wenige Trainingsdaten zur Verfügung. Die Hochdimensionalität sorgt zunächst automatisch für eine große Anzahl von Gewichten, d.h. freien Parametern im Modellansatz. Im neuronalen Kontext gilt, wie auch bei linearen Modellen, dass eine zu große Zahl freier Parameter zur einer Überanpassung des Datensatzes führt, ohne dass das Modell etwas über die Struktur der Aufgabe gelernt hätte. Unabhängig von der externen Spezifikation der Input- und Outputvektoren kann dieser Effekt bei NN sogar noch provoziert werden. Durch eine Erhöhung der Anzahl der Hidden-Layer kann die Zahl der Parameter im Netzwerk soweit gesteigert werden, dass perfektes Auswendiglernen möglich ist.

Das Problem des Lernens besteht also nicht nur darin, eine genügend reichhaltige Funktionenklasse zur Modellierung der Daten zur Verfügung zu stellen, sondern parallel Komplexitätsbeschränkungen durchzuführen, die das Überlernen beschränken.

Messung des Überlernens

Um die Überanpassung zu messen, kann aus dem Trainingsdatensatz mit einem Zufallsgenerator eine nicht zu kleine Validierungsmenge ausgewählt werden. Das überwachte Lernen sorgt dafür, dass der Fehler der Lerndaten (= den restlichen Trainingsdaten) immer weiter abnimmt. Wird dazu parallel der Fehler der Validierungsmenge gemessen, so wird auch dieser in den ersten Epochen, d.h. in den ersten Trainingsdurchgängen, sinken. Nach einer gewissen Zahl von Epochen wird der Fehler in bezug auf die Testmenge aufhören zu sinken oder sogar wieder steigen, obwohl der Fehler bezüglich der Lerndatenmenge weiter fällt.

ABB. 30: DAS PHÄNOMEN DES ÜBERTRAININGS



Quelle: ZIMMERMANN, 1994, S.59

Dies ist ein Zeichen dafür, dass das NN aus der Lernmenge Strukturen herauskristallisiert, die nicht geeignet sind, die grundlegende Dynamik des beobachteten Prozesses zu beschreiben. Das NN beginnt die Lerndaten wiederzugeben, ohne die Grundstruktur zu erkennen.

Für die Messung des Überlernens muss ein Teil der Daten zur Verfügung gestellt werden (ZIMMERMANN, 1994, S.59). Hierdurch verringert sich die Lernmenge zum Trainieren des NN.

Die Datenmenge wird in drei Teile geteilt:

- *Lernmenge*
- *Validierungsmenge*
- *Testmenge*

Die Validierungsmenge soll zur Messung des Übertrainings genutzt werden. Die Nutzung der Validierungsmenge als Schätzung für das Modellverhalten der Generalisierungsmenge beruht auf einer Strukturinvarianzannahme über die Zeit hinweg. Diese ist keineswegs selbstverständlich, aber unumgänglich für jede Prognoserechnung.

Die Testmenge dient zur Bestimmung der Güte des NN. Ein fertig trainiertes NN wird anhand der Testdaten geprüft, inwieweit dieses die Struktur der Daten gelernt hat.

Verfahren zur Vermeidung des Überlernens

Wird der Lernvorgang des NN mit kleinen Gewichten gestartet, so entspricht dies am Anfang dem Training eines linearen Modells. Während des Lernens vergrößern sich die Gewichte und das Modell nimmt unter Berücksichtigung der Anzahl der Hidden-Neuronen mehr und mehr die Züge eines nichtlinearen Modells an. Es passt sich, wenn genügend Hidden-Neuronen zur Verfügung stehen, vollständig den vorgegebenen Daten an. Die einfachste Methode mit dem Phänomen des Übertrainings umzugehen, besteht darin, den Lernvorgang zu stoppen, wenn sich auf der Validierungsmenge eine Überanpassung zeigt. Man hat hier unter den gegebenen Rahmenbedingungen den Punkt der besten beobachtbaren Übereinstimmung gefunden. Der Punkt im Parameterraum, der das Modell mit den besten Interpolationseigenschaften der Trainingsmenge charakterisiert, wird erst später erreicht. Dieser Punkt besitzt aber nicht die besten *Generalisierbarkeitseigenschaften*. Diese Sichtweise zeigt die Priorität von Überlegungen zur Generalisierungsfähigkeit gegenüber der Konvergenzordnung in der Nähe eines lokalen Optimums (ZIMMERMANN, 1994, S.61).

Mit Hilfe dieses Verfahren wird der Lernvorgang abgebrochen, wenn der Fehler der Validierungsmenge wieder ansteigt. Hierdurch ist NN in der Lage den Lernstop annähernd zu bestimmen.

3.4.10 Fazit

Die Anfänge der NN liegen mittlerweile fast 60 Jahre zurück, aber erst in den letzten Jahren gelang ihnen der Durchbruch in der Anwendungsverbretung. NN werden seitdem in verschiedenen fachlichen Forschungsgebieten eingesetzt. In den letzten Jahren fanden sie verstärkt Eingang in die Ökonomie und Ökonometrie.

Die wichtigsten Bestandteile der NN, die vom biologischen Vorbild des Nervensystems abgeleitet werden, sind:

- die **Neuronen** als Verarbeitungseinheit mit dem Aktivierungszustand, der Aktivierungs- und der Ausgabefunktion,
- das **Verbindungsnetzwerk** mit den verschiedenen Verarbeitungs-Layer und den Gewichten und
- der **Lernalgorithmus**.

Als Aktivierungsfunktion eignet sich die **sigmoide** Funktion aus einer Vielzahl zur Verfügung stehender Aktivierungsfunktionen am besten für die Abbildung der nichtlinearen Zusammenhängen in den Datenstrukturen, wie beispielsweise in der Jahresabschlussanalyse.

Als Verbindungsnetzwerk eignet sich ein ebenenweise verbundenes Feedforward-Netz bestehend aus einem Input-Layer, ein oder mehrere Hidden-Layer und einem Output-Layer am besten für eine Klassifizierungsaufgabe. Hierbei handelt es sich um das **Multilayer-Perceptron (MLP)**.

Als Lernalgorithmus für das MLP wird das **Backpropagation-Verfahren** verwendet. Hierbei handelt es sich ein Gradientenverfahren, dass mit Problemen behaftet ist. Zur Lösung dieser Probleme sind in den letzten Jahren geeignete Verfahren entwickelt worden. Auch das größte Problem des "Überlernens" kann durch ein Stop-Verfahren annäherungsweise behoben werden.

Es gibt neben dem Backpropagation-Algorithmus weitere Lernverfahren. Eines davon ist das LVQ-Verfahren. Hierbei handelt es sich um schnelle und einfache Verfahren. Diese Verfahren leiden in der Praxis aber an schlechteren Klassifizierungsleistungen und können deshalb die Backpropagation-Verfahren nicht in jedem Fall ersetzen.

Insgesamt eignet sich das MLP mit Backpropagation-Lernalgorithmus und sigmoider Aktivierungsfunktion aus theoretischer Sicht am besten zur Klassifizierung von Jahresabschlüssen.

3.5 Fuzzy Systeme (FS)

3.5.1 Einführung

Für komplexe und nicht messbare Bewertungen von Ereignissen gewinnen in den letzten Jahren zunehmend Fuzzy Systeme (FS) in der Wissenschaft an Bedeutung (BIETHAHN et al., 1997, S.178). Im technischen Bereich haben die FS mehr und mehr an Popularität gewonnen, nachdem sie sehr gute Ergebnisse in der Reglertechnik erzielt haben (vgl. BIETHAHN et al., 1997).

Die ersten Ansätze der FS liegen bei PLATON. Seine Vermutung, dass eine dritte Region zwischen wahr und falsch gegeben sein müsse, ist der antike Vorläufer des fuzzy-logischen Prinzips. Sein Schüler ARISTOTELES postulierte jedoch das Gesetz vom ausgeschlossenen Dritten, das die Entwicklung logischer und mathematischer Systeme für die nächsten zwei Jahrtausende bestimmen sollte.

BLACK stellte 1937 ein Verfahren vor, mit dem er die Unschärfe von Symbolen numerisch darstellen konnte (BLACK, 1937). Er definierte dabei die Ungenauigkeit oder Vagheit eines Symbols unter Zuhilfenahme dessen Komplements. BLACK ging davon aus, dass es mindestens ein Element gäbe, das weder zum Symbol selbst noch zum Komplement vollständig gehöre. Bei dieser Arbeit stützte er sich auf RUSSEL, dessen Paradoxie "Der Barbier in einer spanischen Kleinstadt" besagt, dass alle Männer, die sich nicht selbst rasieren, vom Barbier rasiert werden. Die in der zweiwertigen Logik nicht lösbare Paradoxie entsteht durch die Frage, wer rasiert den Barbier.

1957 zeigt LUKASIEWICZ, dass es Sätze gibt, denen keiner die Wahrheitswerte "wahr" oder "falsch" zugeordnet werden kann. Hieraus schließt er auf die Existenz eines dritten Wahrheitswertes, den er zwischen "wahr" und "falsch" ansiedelt und "possible" nennt (LUKASIEWICZ, 1957). Der Bezug zu den Fuzzy Systemen ergibt sich dadurch, dass er auch die Möglichkeit nannte, eine unendliche Logik einzuführen. Er ließ dazu alle Zahlen aus dem Intervall $[0,1]$ als Wahrheitswerte zu.

1965 verbindet L. ZADEH in Berkely, USA, die Ideen von BLACK und LUKASIEWICZ und veröffentlicht den grundlegenden Artikel "Fuzzy Sets" (ZADEH, 1965), in dem er die Mathematik der Fuzzy Systeme beschreibt. Sie wurde entwickelt, um Probleme zu modellieren, bei denen Unsicherheiten in den Ausgangsdaten vorhanden sind oder sogenannte unscharfe Inferenzregeln verwendet werden. Bei der Fuzzy-Logik gibt es nicht nur zwei Alternativen für den Wahrheitsgehalt einer Aussage, sondern ein ganzes Kontinuum von Wahrheitswerten (ROJAS, 1996, S.225).

Verwendungsbereiche von Fuzzy Systemen

Nachdem die Theorie der unscharfen Mengen entwickelt worden ist, wurde sie zunächst kommerziell in Japan umgesetzt (Beispiele sind die Steuerung von U-Bahnen und Hubschrauber). Erst seit Anfang der 80er Jahren wurde sie verstärkt in Europa weiterentwickelt und kam hier Anfang der 90er Jahren zum breiten Einsatz. 1995 fand diese Technik auch in ihrem Entwicklungsland USA zunehmende Aufmerksamkeit.

Heutzutage finden wir diese Technik in sehr vielen Gebrauchsgegenständen, wie z.B. Waschmaschine, Staubsauger, Fotoapparate usw. wieder. In der Reglertechnik werden Fuzzy Controller bereits als eine preiswerte und einfache Standardtechnik eingesetzt. In einer Anwendungsstudie der IEEE (Institute of Electrical and Electronics Engineers) von 1996 stellten 90 % der 311 befragten Autoren fest, dass der Einsatz von FS den Aufwand der Reglerentwicklung auf weniger als die Hälfte reduziert hat. 97% der Befragten sagten, dass sie jederzeit wieder FS einsetzen würden, wenn sie hierfür eine geeignete Aufgabenstellung hätten. Die Schlussfolgerung aus dieser Befragung ist, dass sich die FS im technischen Bereich etabliert haben.

Mittlerweile wird das FS auch mehr und mehr in anderen Bereichen angewendet. Neben Fuzzy-Datenanalysen (ZIMMERMANN, 1995) und Fuzzy-Ansätze in der Telekommunikation gibt es unzählige Neuro-Fuzzy-Ansätze. Seit einigen Jahren haben die FS auch Eingang in den betriebswirtschaftlichen Anwendungen gefunden.

Das Problem der Unschärfe

Zur Beschreibung bzw. zur Interpretation von Ereignissen werden typischer Weise in der Wissenschaft mathematische Modelle eingesetzt. Eine generelle Schwierigkeit bei der Beschreibung mittels Modellen liegt darin, dass oftmals erhebliche Idealisierungen notwendig sind, um von einem konkreten Problem zu einem geeigneten mathematischen Modell zu gelangen (NAUCK und KRUSE, 1997, S.4).

Der Ansatz, einen Anteil an fehlender Präzision sowie Vagheit und Unsicherheit beim Modellierungsprozess von vornherein zu tolerieren statt eines aufwendigen exakten Schlussfolgerungsprozesses, gibt sich mit approximativen Schließen zufrieden. Durch die Verwendung nicht perfekter Informationen lässt sich gezielt der Vorteil einer damit verbundener Komplexreduktion gegenüber anderen Systemen ausnutzen. Der Einsatz von Fuzzy Systemen verfolgt genau diese Strategie (NAUCK und KRUSE, 1997, S.5).

Was bedeutet "*Fuzzy*". Dieser Begriff kommt aus der englischen Sprache und meint in etwa "unscharf", "unsicher" oder "verschwommen". Der Begriff *Fuzzy Systeme* bezeichnet somit unscharfe Systeme. Um eine vernünftige Erklärung für den Begriff Fuzzy zu geben, soll hier kurz geklärt werden, um welche Formen von Unschärfe es sich handelt.

Die Unschärfe lässt sich unterteilen in (ROMMELFANGER, 1988, S.4):

- *Lexikalische (sprachliche) Unschärfe*: Sie ist der Ausdruck menschlichen Empfindens, wie z.B. "hoher Verschuldungsgrad", "ausreichender Gewinn", "riskanter Fremdkapitalanteil".
- *Informelle Unschärfe*: Diese Art der Unschärfe bezeichnet die Tatsache, dass bestimmte Begriffe auf sehr subjektiven Festlegungen beruhen, für die zum Teil keine objektive Bewertungsgrößen vorliegen oder diese nicht beschafft werden können. Gemeint sind Begriffe wie "Kreditwürdigkeit" oder "finanzielle Gefährdung".
- *Unschärfe Relationen*: Hierbei handelt es sich um Aussagen, bei denen die Beziehungen zwischen einzelnen Variablen unscharf sind und keinen dichotomen Charakter aufweisen, wie z.B. "nicht viel größer als" und "ungefähr gleich".

Bei diesen Unschärfen handelt es sich um eine grundsätzlich andere Art der Unsicherheit als bei der stochastischen Unsicherheit. Diese beschreibt die Unsicherheit gegenüber dem Eintreten eines Ereignisses. Das Ereignis selbst ist aber klar definiert. Die Unschärfe im Fuzzy System beschreibt die Unsicherheit gegenüber der Definition des Ereignisses selbst. Auch lässt sich diese Art der Unschärfe nicht mit Hilfe der Wahrscheinlichkeitsrechnung behandeln, da die Verknüpfung von subjektiven Kategorien bei menschlichen Bewertungs- und Entscheidungsvorgängen nicht den Axiomen der Stochastik unterliegen. Die Begriffe menschlichen "*Bewertens*" und "*Entscheidens*" sind meist nicht genau definiert. Dies führt zur der wesentlichen Eigenschaft der "*Abstraktionsfähigkeit*".

Abgrenzung zur Wahrscheinlichkeitstheorie

Die FS sind aber nicht mit der Wahrscheinlichkeitstheorie zu verwechseln, mit der sie nur zum Teil verwandt sind. Wahrscheinlichkeitstheoretische Methoden für die Behandlung von unsicherem Wissen werden gewöhnlich auf den Bayes-Ansatz reduziert (NG und ABRAMSON, 1990). Wahrscheinlichkeiten dienen der Beschreibung von statistischen Ungenauigkeiten (PEDRYCZ, 1989), die aufgrund von zufälligen Ereignissen auftreten, und sie tätigen eine Aussage für den Fall, dass ein Experiment mit unsicherem Ausgang wiederholt ausgeführt wird (Gesetz der großen Zahl).

FS finden ihre theoretische Rechtfertigung nicht so sehr in der Wahrscheinlichkeitstheorie, sondern in den algebraischen Methoden, die mit mehrwertigen Logiken assoziiert sind. Sie beschreiben Ungenauigkeiten, die von unzugänglichen menschlichen Wahrnehmungen herrühren. FS und Wahrscheinlichkeitsrechnung sind trotz ihrer Unterschiede gemeinsam zu nutzen und ergänzen sich gegenseitig.

Beispiel für unscharfes Wissen

Als Beispiel sei folgendes Wissensfragment aus einem medizinischen Expertensystem angeführt (von ALTROCK, 1997, S.194):

„Bei einem Hepatitiskranken tritt in 60 Prozent aller Fälle starkes Fieber auf, bei 45 Prozent eine auffällige Gelbfärbung der Haut und bei 30 Prozent starke Übelkeit ein.“

In diesem Beispiel sind beide Elemente – Wahrscheinlichkeiten und unscharfe Formulierungen - enthalten. Sind die Symptome eines Patienten bekannt, so kann die Wahrscheinlichkeit nach der Bayesschen Theorie berechnet werden, ob es sich um einen Hepatitiskranken handelt. Die Symptome sind hier nicht klar beschrieben, sondern nur durch die unscharfen Bezeichnungen "stark" und "auffällig".

Problematisch wird es, wenn angegeben werden muss, was starkes Fieber ist. Liest man in Lehrbüchern nach oder fragt man Ärzte, so wird man keine eindeutige Antwort erhalten. Auch wenn sich vielleicht die meisten Ärzte darauf einigen können, dass die Schwelle "so etwa" bei 39 C liegt, so heißt dies lange noch nicht, dass ein Patient mit 38,9 C überhaupt kein Fieber hat. Während ein Patient mit einer nur um 0,1 C höheren Körpertemperatur in vollem Maße starkes Fieber hat. Wäre dies so, müsste auch die Umkehrung gelten, dass nämlich die genaue Angabe der Körpertemperatur auch die Genauigkeit der Diagnose impliziert.

Wie in diesem Beispiel kann auch die Klassifizierung von Jahresabschlüssen für die Diagnose des finanziellen Zustandes der Unternehmen nicht nach scharfen Grenzen erfolgen. Wenn die Schwelle der finanziellen Gefährdung "so etwa" bei einer Gesamtkapitalrentabilität von 0 % liegt, kann nicht davon ausgegangen werden, dass Unternehmen mit einer Gesamtkapitalrentabilität von 0,1 % überhaupt nicht gefährdet sind.

Da keine Theorie über die Jahresabschlussanalyse vorliegt, können keine mathematischen Funktionen zwischen den Kennzahlen gebildet werden. Dementsprechend liegt nur unscharfes Wissen über die Beziehungen der Kennzahlen vor. Bei unscharfen Wissen macht es keinen Sinn, die Klasseneinteilung anhand einer scharfen Menge mit scharfen Abgrenzungen vorzunehmen. In diesem Fall würde man Kennzahlen durch Begriffe der lexikalischen Unschärfe überdurchschnittlich, durchschnittlich oder unterdurchschnittlich unterteilen.

Diese Begriffe der lexikalischen Unschärfe können nicht durch scharfe Intervalle definiert werden. Angenommen es existiert eine Klasseneinteilung der Gesamtkapitalrentabilität mit der Ausprägung „überdurchschnittlich“ und „unterdurchschnittlich“. Die Aufteilung der Menge erfolgt, indem in die obere Hälfte die Unternehmen mit einer Gesamtkapitalrentabilität größer als das arithmetische Mittel

und in die unteren Hälfte die Unternehmen mit einer Gesamtkapitalrentabilität kleiner als das arithmetischen Mittel sortiert werden.

Der Mengenbegriff impliziert eine digitale entweder-oder-Struktur: Entweder ist ein kritischer Wert (z.B. das arithmetische Mittel) überschritten oder nicht. Hierdurch können Unternehmen jeweils in eine andere Klasse eingeordnet werden, obwohl sich ihre Gesamtkapitalrentabilität nur geringfügig voneinander unterscheidet und somit in ihrer "finanziellen Gefährdung" nicht unterschiedlich zu beurteilen sind. Gerade bei Kennzahlen wie Gesamtkapitalrentabilität liegt eine Verteilung vor, bei der viele Unternehmen nur eine geringe Abweichung vom arithmetischen Mittel aufweisen, und somit bei einer scharfen Abgrenzung viele Unternehmen mit einer ähnlichen absoluten Höhe der Gesamtkapitalrentabilität in eine unterschiedliche Klasse unterteilt werden.

Deshalb müssten die Begriffe der lexikalischen Unschärfe durch unscharfe Mengen beschrieben werden. Zwar ist eine scharfe Grenzziehung typisch für eine digitale Welt, sie entspricht aber nicht der menschlichen Beurteilung. Eine geringfügige Überschreitung von Grenzwerten wird – je nach Situation – noch toleriert oder durch linguistische Attribute gekennzeichnet.

3.5.2 Der Begriff der unscharfen Mengen

Die FS verwenden zur Berechnung deshalb Fuzzy Mengen. In der Theorie der Fuzzy Mengen wird das klassische Mengenkonzept erweitert, indem durch Fuzzifizierung, d.h. eine Aufweichung der Menge, ein gleitender Übergang zwischen den Klassen ermöglicht wird.

Da der Mensch nur eine unscharfe Vorstellung davon hat, welche Kennzahlenausprägung die Menge der Gesamtkapitalrentabilität hat, reicht der klassische, auf der zweiwertigen Logik beruhende Mengenbegriff nicht aus, um den Begriff "überdurchschnittliche Kapitalrentabilität" problemadäquat abzubilden (vgl. ROMMELFANGER, 1988).

Es gibt verschiedene Interpretationen für die Semantik von Fuzzy Mengen. Eine davon ist die Möglichkeitstheorie, die auf der Basis der Fuzzy Mengen analog zur Wahrscheinlichkeitstheorie beschrieben werden kann. Sei dazu eine Variable u gewählt, die Werte aus der Grundmenge X annimmt. Dann lassen sich durch eine Fuzzy Menge $\tilde{A} = \{(x, m_{\tilde{A}}(x)); x \in X\}$ "die möglichen Werte von u " beschreiben. Der gravierende Unterschied zwischen der Möglichkeitstheorie und der Wahrscheinlichkeitstheorie besteht darin, dass die Möglichkeit subjektiv bestimmt wird, die Wahrscheinlichkeit hingegen formal berechnet oder empirisch ermittelt wird (vgl. BÖHME, 1993). Folgendes Beispiel soll dies veranschaulichen:

Man betrachtet zwei Wassergläser, die mit einer Flüssigkeit gefüllt sind. Auf beiden Gläsern befinden sich Aufkleber, die über die genießbarkeit der jeweiligen Flüssigkeit

Auskunft geben. Auf dem einem Glas steht "Diese Flüssigkeit ist zum Grad 0,9 genießbar.", und das andere Glas trägt die Aufschrift "Diese Flüssigkeit ist mit der Wahrscheinlichkeit 0,9 genießbar". Beim Trinken aus dem ersten Glas stellt sich eine Trübung des Wohlbefindens ein, wohingegen die Wahrscheinlichkeitsaussage auf dem zweiten Glas keine Aussage über den Inhalt dieses Glases, sondern über den Inhalt von vielen Gläsern, aus denen eines ausgewählt wird, macht. Die Unsicherheit, die durch die FS zu modellieren versucht wird, hat also gegenüber der Wahrscheinlichkeit den großen Vorteil, dass sie unsichere Aussagen zu einem bestimmten und damit konkreten Objekt ermöglicht, was sich nicht nur für computergestützte Verarbeitung als hilfreich erweist. Zusammenfassend kann festgestellt werden, dass mit FS lokale Unsicherheiten und mit der Wahrscheinlichkeitstheorie globale Unsicherheiten beschrieben werden.

Dieses Beispiel aus dem täglichen Leben lässt sich auch auf die Diagnose des finanziellen Zustandes eines Unternehmens übertragen. Die Beurteilung eines Unternehmens lautet: "Dieses Unternehmen ist mit dem Grad von 0,9 finanziell gefährdet". Eine andere Beurteilung lautet: "Das Unternehmen wird mit einer Wahrscheinlichkeit von 0,9 insolvent." Aus der ersten Aussage kann geschlossen werden, dass dieses Unternehmen finanzielle Probleme aufweist. Die zweite Aussage gibt keine Auskunft darüber, ob dieses Unternehmen finanzielle Probleme hat, sondern informiert darüber, wie hoch die Wahrscheinlichkeit einer Insolvenz ist. Es liegen aber keine Informationen darüber vor, wie die finanzielle Situation im Falle einer Solvenz ist.

Beschreibung der Fuzzy Mengen

Im Unterschied zu gewöhnlichen Mengen, bei denen Elemente eindeutig zu einer Menge gehören oder nicht zu ihr gehören, werden bei unscharfen Mengen beliebige graduelle Zugehörigkeiten zwischen 0 und 1 zugelassen. Eine unscharfe Menge wird durch die **Zugehörigkeitsfunktion** charakterisiert.

Definition

Es sei X eine Grundmenge. Eine unscharfe Menge oder **Fuzzy-Menge** \tilde{A} einer Menge X ist eine Menge von geordneten Paaren (vgl. ROMMELFANGER, 1988):

$$\tilde{A} = \{(x, m_{\tilde{A}}(x)); x \in X\}$$

Dabei ist $m_{\tilde{A}}(x)$ eine Funktion mit $m_{\tilde{A}}(x): X \rightarrow [0,1]$, die den Grad angibt, zu dem ein Element $x \in X$ in der Menge \tilde{A} enthalten ist.

Das Intervall der Zugehörigkeitsfunktion ist üblicherweise auf dem Bereich 0 ... 1 beschränkt; man spricht von einer normalisierten, unscharfen Menge. Eine unscharfe Menge wird ganz durch die Zugehörigkeitsfunktion bestimmt. Scharfe Mengen stellen

nur einen Spezialfall der unscharfen Mengen dar, weil der Bildbereich der Zugehörigkeitsfunktionen auf die Werte 0 oder 1 beschränkt wird.

Empirische psycholinguistische Forschungen (von ALTROCK, 1996, S. 30) haben ergeben, dass eine Zugehörigkeitsfunktion folgende Eigenschaften aufweisen sollte:

- $m(x)$ sei stetig über X
- $m(x)$ sei stetig über X
- $m(x)$ sei stetig über x
- $m: \min_m \{ \max_x \{ m(x) \} \}$ für alle X

Eine Fuzzy Menge erlaubt somit die mathematische Darstellung einer unscharf beschriebenen Größe. Fuzzy Mengen können einen graphischen Verlauf einer Dreiecksfunktion, eines Trapezes, einen s-förmigen Verlauf oder ähnliche Formen haben.

Linguistische Variable

Besteht eine Variable nicht aus einer numerischen Ausprägung im klassischen Sinne, sondern aus einer Anzahl von Fuzzy Mengen, wird diese als *linguistische Variable* bezeichnet. Sie beschreibt die Partitionierung eines Grundbereiches, dessen Werte nicht Zahlen, sondern Symbole wie klein, mittel und groß sind (BOTHE 1998, S.25). Die Fuzzy Mengen werden durch Wörter oder Satzfragmente beschrieben. Wenn die Gesamtkapitalrentabilität eine linguistische Variable ist, wird sie durch die Fuzzy Menge {überdurchschnittlich, durchschnittliche, unterdurchschnittlich} qualitativ beschrieben.

Definition

Eine *linguistische Variable* ist eine Variable, die keinen numerischen Wert hat (wie im Falle einer deterministischen Variable), sondern aus linguistischen Fragmenten besteht. Der Inhalt jeder dieser Terme ist durch eine Fuzzy Menge über eine Basisvariable festgelegt.

Der Grad, mit dem ein technischer Wert dem linguistischen Konzept eines Terms einer linguistischen Variablen entspricht, wird Grad der Zugehörigkeit genannt. Bei kontinuierlichen Variablen wird dieser durch die Zugehörigkeitsfunktion beschrieben. Diese Zugehörigkeitsfunktion ordnet jedem Wert einer technischen Größe den Zugehörigkeitsgrad zu dem entsprechenden linguistischen Term zu. Eine linguistische Variable beschreibt eine komplette Entscheidungsgröße unserer Umgangssprache (vgl. von ALTROCK, 1996).

Aufgrund seines begrenzten Ausdrucks- und Differenzierungsvermögens kann der Mensch die möglichen Ausprägungen einer linguistischen Variable nur mit wenigen verbalen Begriffen beschreiben, die nicht eindeutig und exakt voneinander abgegrenzt werden können. Dennoch ist man in der Lage, eine konkrete Ist-Ausprägung in dieses unscharfe Klassifizierungsschema einzuordnen und darauf aufbauend eine konsistente Schlussfolgerung abzuleiten. Die menschliche Fähigkeit, anhand einiger typischer Werturteile die gesamte Bandbreite der möglichen Ist-Ausprägungen beurteilen zu können, findet im Konzept der linguistischen Variablen ihre Entsprechung, indem die vom Experten als typische Ausprägungen genannten unscharfen Klassifizierungen vorgegeben und durch geeignete Zugehörigkeitsfunktionen abgebildet werden.

Bei der Definition der linguistischen Variablen stellen sich folgende Fragen:

- Wieviele Terme soll jede linguistische Variable enthalten?
- Welcher Typ "Zugehörigkeitsfunktion" soll verwendet werden?
- Wie lassen sich plausible Zugehörigkeitsfunktionen definieren?

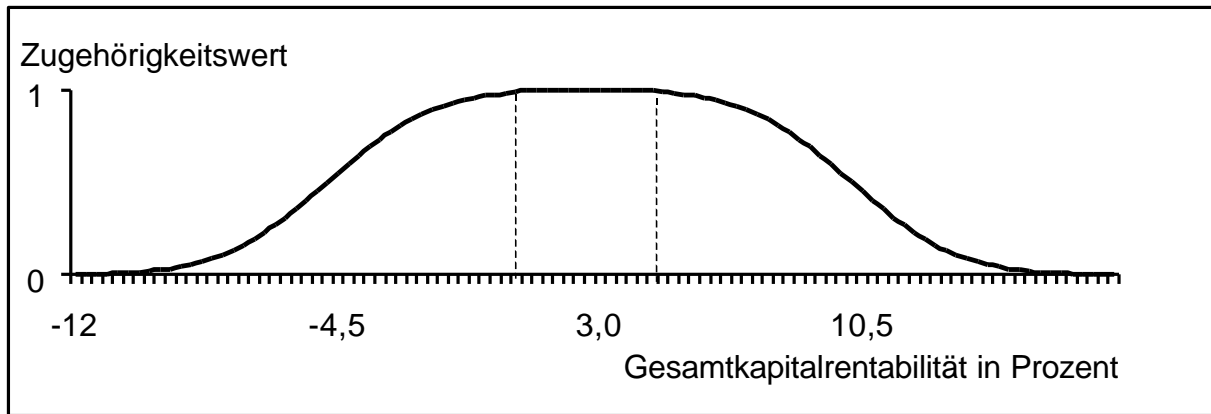
Die Festlegung der Terme erfolgt heuristisch. Fast alle Variablen haben eine Termenanzahl zwischen 3 und 7. Es sollte mit einer minimalen Termzahl begonnen werden, denn später können leichter Terme hinzugefügt als weggenommen werden.

Beispiel

Wenn das oben erwähnte Beispiel zur Diagnose des finanziellen Zustandes eines Unternehmens weitergeführt wird und statt zwei Klassen die Menge der Gesamtkapitalrentabilität in drei Terme: überdurchschnittlich, durchschnittlich und unterdurchschnittlich, aufgeteilt wird, könnten diese Mengen mit den Zugehörigkeitsfunktionen in Abb. 31, Abb. 32, Abb. 33 und Abb. 34 beschrieben werden. Die Zugehörigkeitsfunktionen ermitteln für den jeweiligen Wert der Gesamtkapitalrentabilität den Zugehörigkeitswert des entsprechenden Terms der linguistischen Variable.


In Abb. 34 werden die Zugehörigkeitsfunktionen aller Terme der linguistischen Variable gleichzeitig dargestellt. Hierdurch wird ersichtlich, dass ein Wert der linguistischen Variable gleichzeitig mehrere Zugehörigkeitswerte verschiedener Terme aufweisen kann.

ABB. 31: ZUGEHÖRIGKEITSFUNKTION DER FUZZY MENGE
"DURCHSCHNITTLICHE GESAMTKAPITALRENTABILITÄT"



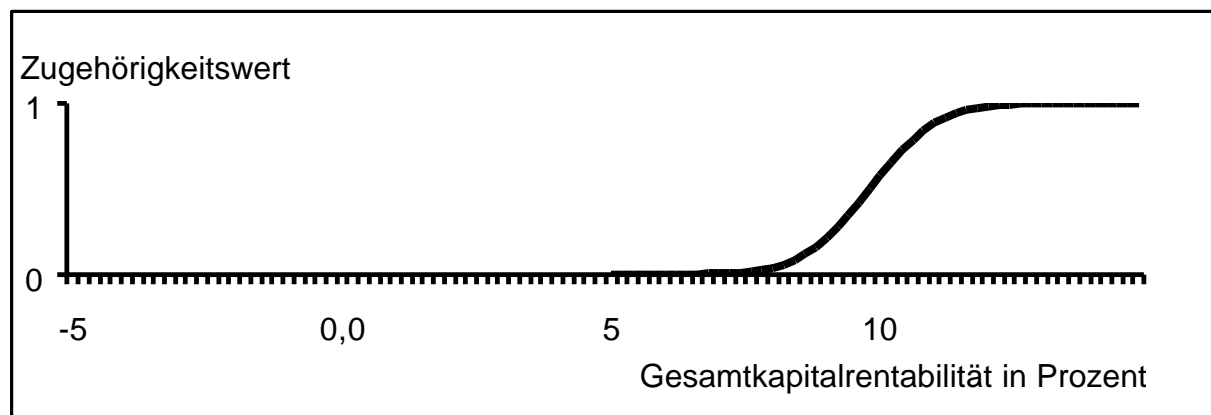
Quelle: Eigene Darstellung

ABB. 32: ZUGEHÖRIGKEITSFUNKTION DER FUZZY MENGE
"UNTERDURCHSCHNITTLICHE GESAMTKAPITALRENTABILITÄT"




Quelle: Eigene Darstellung

ABB. 33: ZUGEHÖRIGKEITSFUNKTION DER FUZZY MENGE
"ÜBERDURCHSCHNITTLICHE GESAMTKAPITALRENTABILITÄT"



Quelle: Eigene Darstellung

Abb. 34: Linguistische Variable "Gesamtkapitalrentabilität"

Quelle: Eigene Darstellung

Ermittlung der Zugehörigkeitsfunktion

Die Qualität der Abbildung einer linguistischen Variablen mittels Fuzzy Mengen hängt maßgeblich davon ab, inwieweit die gewählten Zugehörigkeitsfunktionen die Einschätzungen des Experten zutreffend wiedergeben (TERANO et al., 1992, S.22). Da die Zugehörigkeitsfunktion das individuelle Beurteilungsvermögen eines Experten repräsentiert, ist ihr Verlauf stark subjektiv geprägt (vgl. ROMMELFANGER, 1988).

Trotz der hohen Bedeutung, die der Ermittlung der Zugehörigkeitsfunktion zukommt, fehlen bis heute noch geeignete Methoden zur Auswahl, Messung und Umsetzung von Daten (JENßEN, 1999, S.107). Auch ZIMMERMANN (1987) stellt fest:

“... at the very beginning there should be a semantic definition of the central concepts. ... Unfortunately this has not yet been possible for the concept of membership. Membership has a clear cut formal definition. However, explicit requirements for this empirical/experimental measurement are still missing.“

Gerade wegen der bestehenden Unschärfe wird der Experte keine exakte Funktion, sondern regelmäßig nur einige charakteristische Punkte bestimmen können, denen dann annäherungsweise Ableitungen der Zugehörigkeitsfunktion zugrunde gelegt werden. Hierfür werden meist einfache Funktionsformen verwendet (vgl. ROMMELFANGER, 1988)

Die Funktionen können durch wenige Parameter bestimmt werden. Folgende Funktionen stehen u.a. zur Verfügung:

➤ *stückweise linear*

$$\text{Trapez: } f(x, a, b, c, d) = \begin{cases} 0, & x \leq a, x \geq d \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ 1, & b \leq x \leq c \\ \frac{d-x}{d-c}, & c \leq x \leq d \end{cases} \quad \text{mit } a \leq b \leq c \leq d$$

mit den Sonderfall: $b = c \Rightarrow$ dreiecksförmige Zugehörigkeitsfunktion

➤ *stetige Funktionen*

\Rightarrow normierte Gauß-Funktion

$$f(x; c, s) = e^{-\frac{(x-c)^2}{2s^2}}$$

\Rightarrow sigmoide Funktion

$$f(x; a, c) = \left[1 + e^{-a_1(x-c)} \right]^{-1}$$

\Rightarrow Differenz sigmoider Funktionen

$$f(x; a_1, c_1, a_2, c_2) = \left[1 + e^{-a_1(x-c_1)} \right]^{-1} - \left[1 + e^{-a_2(x-c_2)} \right]^{-1}$$

\Rightarrow verallgemeinerte Glockenfunktion

$$f(x; a, b, c) = \left[1 + \left| \frac{x-c}{a} \right|^{2b} \right]^{-1}$$

Bei nicht-technischen Anwendungsproblemen empfiehlt sich die Verwendung von s-förmigen (z.B. die "Differenz sigmoider Funktionen" oder die "normierte Gauß-Funktion") Zugehörigkeitsfunktionen (vgl. ROMMELFANGER, 1988), die sich der Nutzentheorie bzw. der Normalverteilung annehmen. Empirische Untersuchungen haben ergeben, dass sie das menschliche Beurteilungsverhalten besonders gut beschreiben (ZIMMERMANN, 1987, S.208ff.). S-förmige Funktionen scheinen besonders realitätsnah. Da die Eckwerte der Zugehörigkeitsfunktion nur unscharf

bestimmt werden können, sollten möglichst weiche, fließende Übergänge an deren Stelle treten.

Die Zugehörigkeitsfunktionen werden dahin modifiziert, dass sie ein "Plateau" aufweisen. Dies soll dazu dienen, dass eine Bandbreite der Kennzahlenausprägung abgebildet werden kann.

Bei der Bestimmung der Zugehörigkeitsfunktion wird zwischen den Plateaus ein s-förmiger Kurvenverlauf unterstellt. Es ist zu beachten, dass die Addition von zwei Zugehörigkeitswerten im Überlappungsbereich maximal 1 werden darf, weil höhere Werte nicht sinnvoll interpretiert werden können. Somit kann eine Ist-Ausprägung, die einer Fuzzy Menge voll angehört, nicht gleichzeitig partiell einer anderen unscharfen Menge angehören.

3.5.3 Fuzzy-Mengen Operationen und ihre Eigenschaften

In der klassischen Logik werden häufig Kombinationen von mehreren Eingangsvariablen verknüpft, um eine oder mehrere Ausgangsvariablen zu erhalten (z.B. "und", "oder", "nicht"). Um mit der Fuzzy-Logik sinnvoll arbeiten zu können, müssen diese Verknüpfungen als Operationen auf den Fuzzy Mengen definiert werden. Da die Fuzzy-Logik aber keine zweiwertige Logik ist, können diese Operationen nicht in Form von Tabellen definiert werden, wie in der klassischen Logik, sondern als Mengenoperationen. In der klassischen Logik können alle Operationen auf die Grundverknüpfungen "und", "oder" und "nicht" zurückgeführt werden. In der zweiwertigen Logik ist die Anzahl der möglichen Verknüpfungen bei gegebener Anzahl der Eingangsgrößen beschränkt. Dies ist aber bei der Fuzzy-Logik nicht der Fall, da die Eingangsgrößen kontinuierlich sind und somit prinzipiell jede Funktion als Verknüpfung in Frage kommt.

Um die mengentheoretischen Basisoperationen Durchschnitt, Vereinigung und Komplementbildung für Fuzzy Mengen zu definieren, müssen die logischen Operatoren, die klassisch nur für die Werte 0 und 1 definiert sind, auf das Einheitsintervall definiert werden. Hier wird die Verbindung zwischen der Theorie der Fuzzy Mengen und mehrwertigen Logikkalkülen deutlich (NAUCK und KRUSE, 1997, S. 8).

Operationen von Fuzzy Mengen

Aus der Fuzzy-Mengenlehre kann eine Fuzzy-Logik aufgebaut werden (ROJAS, 1996, S.233). Die Schnittmenge entspricht dem logischen UND (ROMMELFANGER, 1988, S.17). Dem logischen UND kann in der Fuzzy-Logik die Minimum Funktion (vgl. Abb. 35) gleichgesetzt werden.

Definition der „Schnittmenge“ (ROMMELFANGER, 1988, S.17)

Minimum-Operator

Die Zugehörigkeitsfunktion der Schnittmenge von zwei Fuzzy-Mengen \tilde{A} und \tilde{B} mit der Zugehörigkeitsfunktion $m_{\tilde{A}}(x)$ und $m_{\tilde{B}}(x)$ ist definiert bei

$$m_{\tilde{A} \cap \tilde{B}}(x) = \min(m_{\tilde{A}}(x), m_{\tilde{B}}(x)) \quad \forall x \in X$$

Die Vereinigungsmenge entspricht dem logischen ODER (ROMMELFANGER, 1988, S.17). Dem logischen ODER kann in der Fuzzy-Logik die Maximum Funktion (vgl. Abb. 36) gleichgesetzt werden.

Definition des „Vereinigungsmenge“ (ROMMELFANGER, 1988, S.17)

Maximum-Operator

Die Zugehörigkeitsfunktion der Vereinigungsmenge von zwei Fuzzy-Mengen \tilde{A} und \tilde{B} mit der Zugehörigkeitsfunktion $m_{\tilde{A}}(x)$ und $m_{\tilde{B}}(x)$ ist definiert bei

$$m_{\tilde{A} \cup \tilde{B}}(x) = \max(m_{\tilde{A}}(x), m_{\tilde{B}}(x)) \quad \forall x \in X$$


Definition des „Komplements“ (ROMMELFANGER, 1988, S.18)

Nicht-Operator


Die Zugehörigkeitsfunktion des Komplements von der Fuzzy-Menge \tilde{A} ist definiert bei

$$m_{\tilde{A}^c}(x) = 1 - m_{\tilde{A}}(x) \quad \forall x \in X$$

ABB. 35: SCHNITTMENGE (MIN-OPERATOR)



Quelle: Eigene Darstellung

ABB. 36: VEREINIGUNGSMENGE (MAX-OPERATOR)

Quelle: Eigene Darstellung

Beim Min-Operator wird von beiden Mengen jeweils der kleinste, beim Max-Operator der größte Wert ausgewählt. Die schwarze Linie stellt in den Abb. 35 und Abb. 36 jeweils die Ergebnismenge dar.

In der Fuzzy-Logik spielt der *Nicht-Operator* allerdings keine große Rolle, weil bereits in Fuzzy Mengen definiert ist, dass eine Information mehr oder weniger zutrifft, so dass eine harte Verneinung nicht mehr sinnvoll ist. Wird eine Information in "verneinter" Form gebraucht z.B. "Wenn der Fremdkapitalanteil nicht hoch ist ..." dann wird in der Regel ohnehin direkt eine Fuzzy Menge "nicht hoch" definiert und dies nicht aus einer Fuzzy Menge "hoch" durch eine *Nicht-Operation* abgeleitet.

Die verallgemeinerten logischen Operationen legen fest, wie mit „partieller Wahrheit“ gerechnet werden sollte. Für die Vereinigungsmenge und Schnittmenge gelten das Kommutativ-, Assoziativ-, Adjunktiv- und Distributivgesetz (ROMMELFANGER, 1988, S.19).

Anwendung der Operatoren

Bei der Nachbildung menschlicher Entscheidung sind die hier vorgestellten verallgemeinerten logischen Operationen oft nicht geeignet und liefern Ergebnisse, die der Intuition nicht entsprechen. Die Diagnose des finanziellen Zustandes eines Unternehmens wurde bisher über die Kennzahl Gesamtkapitalrentabilität beschrieben. Für eine bessere Diagnose sollten aber weitere Kennzahlen verwendet werden. Als zusätzliche Kennzahlen können der dynamische Verschuldungsgrad und der Fremdkapitalanteil hinzugezogen werden. Für die Diagnose müssen die drei Kennzahlen miteinander verknüpft werden. Durch die Verknüpfung der Zugehörigkeitswerte der drei Kennzahlen durch einen Operator kann der Grad der Zugehörigkeit zur Klasse der "finanziellen Gesundheit" der Unternehmen ermittelt werden.

Bei der Frage, welcher der Operatoren herangezogen werden soll, wird die Nachbildung menschlicher Entscheidungen mit den beiden Operatoren "min" und "max" oft als nicht geeignet angesehen, weil sie keine realistischen Ergebnisse liefern, da der Mensch einen Ausgleich zwischen den beiden verwendeten Eigenschaften vornimmt. Wenn mehrere Kriterien eine Rolle spielen, dann sollten kompensatorische Effekte berücksichtigt werden, um menschliche Entscheidungen nachzubilden.

Beispielsweise ist ein Unternehmen mit einer sehr hohen Gesamtkapitalrentabilität und einem hohen Fremdkapitalanteil weniger "finanziell gefährdet" als ein Unternehmen mit einer sehr niedrigen Gesamtkapitalrentabilität und einem niedrigeren Fremdkapitalanteil.

Deshalb werden zur Abbildung von realistischen Ereignissen die kompensatorischen Operatoren „arithmetisches Mittel“, „geometrisches Mittel“, „fuzzy-und“, „fuzzy-oder“ und „kompensatorisches-und“ als mögliche mittelnde Operatoren herangezogen. Je nach gewähltem g bewegen sich diese Operatoren zwischen dem Minimum und dem Maximum bzw. dem arithmetischen Mittel (vgl. ZIMMERMANN, 1995). Zur Modellierung der „und“ – bzw. – „oder“ – Verknüpfung lassen sich in solchen Fällen beispielsweise folgende Operatoren einsetzen (vgl. NAUCK und KRUSE, 1997):

$$m_{und}(m_1(x), m_2(x)) = g \cdot \min(m_1(x), m_2(x)) + (1-g) \cdot \frac{m_1(x) + m_2(x)}{2},$$

$$m_{oder}(m_1(x), m_2(x)) = g \cdot \max(m_1(x), m_2(x)) + (1-g) \cdot \frac{m_1(x) + m_2(x)}{2},$$

$$m_{komp}(m_1(x), m_2(x)) = (m_1(x) \cdot m_2(x))^{1-g} \cdot (m_1(x) + m_2(x) - m_1(x) \cdot m_2(x))^g,$$

$$m_{komp2}(m_1(x), m_2(x)) = (m_1(x) \cdot m_2(x))^{1-g},$$

wobei jeweils $g \in [0,1]$ gilt.

Und als mittelnde Operatoren,

$$m_{arith.}(m_1(x), m_2(x)) = \frac{m_1(x) + m_2(x)}{2},$$

$$m_{geom}(m_1(x), m_2(x)) = (m_1(x) \cdot m_2(x))^{0.5},$$

3.5.4 Berechnung von Fuzzy-Inferenzen

Auf der Grundlage der Operatoren können *Fuzzy-Inferenzregeln* definiert werden. Der Prozess der Schlussfolgerung wird als Inferenz bezeichnet. Hierzu werden die das System beschreibenden "*WENN... DANN... – Regeln*" ausgewertet.

Wenn Fuzzy-Methoden zur Systembeschreibung benutzt werden sollen, wird das Übertragungsverhalten nicht durch ein Gleichungssystem, sondern mit Hilfe von verbalen "*WENN... DANN... – Regeln*" ausgedrückt. Diese Regeln werden zu einer Regelbasis zusammengefasst. Das Übertragungsverhalten des Systems ist damit nicht exakt, sondern unscharf festgelegt. Bei einer Beschreibung der Regelungsschärfen durch Intervalle würden scharfe Eingangswerte auf scharfe Ausgangsintervalle abgebildet. Eine unscharfe Systembeschreibung mit Hilfe unscharfer Mengen erzeugt dementsprechend unscharfe Ausgangsmengen. Die zusätzliche Information der Expertenbewertung pflanzt sich also auf den Ausgang fort.

Zur Beschreibung eines unscharfen Systems müssen zunächst die beteiligten linguistischen Variablen bestimmt und die Variabilitätsbereiche mit Hilfe von unscharfen Mengen partitioniert werden. Anschließend werden die Übertragungsregeln von Experten aufgestellt oder in einem automatischen Prozess generiert. Dabei können unterschiedliche Regeltypen verwendet werden, die den Schlussfolgerungs- oder Inferenzmechanismus mitbestimmen. Auf der Grundlage der logischen Operatoren werden Fuzzy-Inferenzregeln definiert. Sie sind in den letzten Jahren vor allem in Verbindung mit Expertensystemen intensiv erforscht worden (vgl. NAUCK et al., 1994). Es wird damit versucht, Regeln zu modellieren, die nur unscharf modelliert werden können.

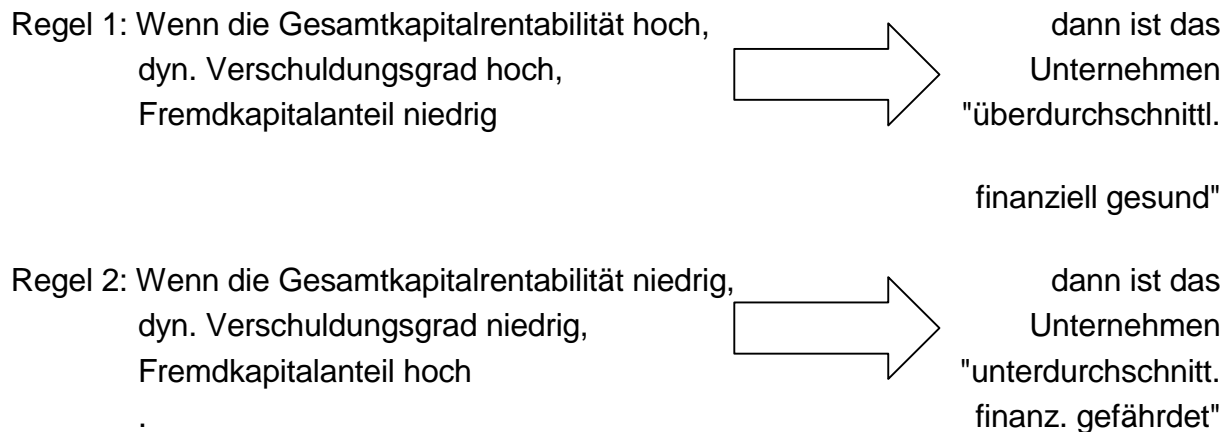
Theoretische Herleitung der Inferenzmechanismen

Folgendermaßen können diese Inferenzmechanismen hergeleitet werden: Unscharfe Systeme können als universelle Approximatoren angesehen werden. Sie können also jede reelle stetige Funktion infinitesimal genau nachbilden. Im allgemeinen wird dabei eine infinite Anzahl von Regeln vorausgesetzt (vgl. WAN, 1994). Die Genauigkeit der Approximation steht in Konkurrenz zur Interpretierbarkeit des resultierenden Übertragungsverhaltens, das bei einer geringen Regelzahl größer wird.

Unscharfe *Wenn... Dann... -Regeln* können als unscharfe Relationen interpretiert werden, die zur Funktionsapproximation dienen. Die Bildung des *kartesischen Produkts* stellt eine Methode dar, mit der man von eindimensionalen zu mehrdimensionalen Mengen gelangt. Das *kartesische Produkt* von zwei scharfen Grundmengen X und Y ist folgendermaßen definiert: $X \times Y = \{(x, y) \mid x \in X \text{ und } y \in Y\}$.

Bei der Erweiterung für zwei Fuzzy Mengen $\tilde{A} \in X$ und $\tilde{B} \in Y$, die durch ihre jeweilige Zugehörigkeitsfunktion $m_{\tilde{A}}$ bzw. $m_{\tilde{B}}$ $\tilde{A} \times \tilde{B}$ gegeben sind, ist das *kartesische Produkt*

Folgende Beispielsregeln können aufgestellt werden:



Die Wahrheitswerte seien die Zahlen 0,9 für die Gesamtkapitalrentabilität, 0,2 für den dynamischen Verschuldungsgrad und 0,1 für das Fremdkapitalanteil. In diesem Fall erhalten wir bei der Anwendung des "fuzzy-oder" bzw. "fuzzy-und" ($\gamma = 0,7$):

R1:

$$\mu_{\text{oder}}(\mu_{\text{Gesamtkapitalrent., hoch}}(0,9), \mu_{\text{dyn. Verschuldungsgrad, hoch}}(0,2), \mu_{\text{Fremdkapital., niedrig}}(0,1)) = 0,75$$

R2:

$$\mu_{\text{und}}(\mu_{\text{Gesamtkapitalrent., hoch}}(0,9), \mu_{\text{dyn. Verschuldungsgrad, niedrig}}(0,8), \mu_{\text{Fremdkapital., hoch}}(0,9)) = 0,89$$

Dies wird durch den Fuzzy-Inferenzmechanismus so interpretiert, dass die Regeln R1 und R2 nur partiell anwendbar sind, d.h. Regel 1 zu 0,75 und Regel 2 zu 0,89.

Die Beschreibung des finanziellen Zustandes eines Unternehmens erfolgt durch eine Vielzahl von "Wenn ... Dann-Regeln". Die einzelnen Kennzahlen werden über die jeweiligen Operationen miteinander verknüpft. Hierdurch wird der Grad der Zugehörigkeit für die Schlussfolgerung der Fuzzy-Regel ermittelt. Diese ist in dem zugrundeliegenden Beispiel die "finanzielle Gesundheit" mit den Fragmenten überdurchschnittlich, durchschnittlich und unterdurchschnittlich für ein Unternehmen exemplarisch dargestellt.

In Tab. 4 ist die Beschreibung beispielhaft für den finanziellen Zustand über vier verschiedene Fuzzy-Regeln beschrieben.

TAB. 4: BEISPIELE FÜR REGELN MIT ANWENDUNG DES "FUZZY-UND".

Regel-Nr.	Gesamtkapital- rentabilität	Dynamischer Verschuldungs-	Fremdkapital- anteil	Zugehörigkeit des finanziellen Zustandes		
				Überdurch- schnittlich	Durch- schnittlich	Unterdurch- schnittlich
1	Hoch 1,0	Hoch 1,0	Niedrig 1,0	1,0		
2	Niedrig 0,1	Niedrig 0,2	Hoch 0,0			0,03
3	Niedrig 0,1	Mittel 0,7	Mittel 0,1		0,16	
4	Hoch 0,9	Mittel 0,7	Mittel 0,1		0,25	

Quelle: Eigene Berechnungen

Durch den Fuzzy-Inferenzmechanismus wird der Zugehörigkeitsgrad zur Klasse "finanziell gesund" mit den drei Fragmenten überdurchschnittlich, durchschnittlich und unterdurchschnittlich ermittelt. Je nachdem, wie die Schlussfolgerung in der Regel lautet, wird der Grad der Zugehörigkeit für die jeweilige Klasse ermittelt.

Häufig ist die Situation so, dass nicht nur genau eine Regel zutrifft, sondern mehrere gleichzeitig in die Inferenz eingehen (vgl. Beispiel in Tab. 4). Die Stärke des Fuzzy-Logik-Ansatzes besteht gerade darin, dass die Regeln, die der Experte nicht explizit mit in die "idealtypische" Merkmalskombination aufgenommen hat, mit in die Schlussfolgerung einbezogen werden (ROMMELFANGER, 1991, S. 41).

Für die Gesamtbeurteilung werden alle Regeln einbezogen, deren Erfüllungsgrad positiv ist. Diese Regeln beinhalten Expertenwissen, das die beurteilende Situation mehr oder weniger beschreibt. Dabei gehen die Regeln nur in dem Maße in das Gesamturteil mit ein, in dem die Prämissen der Regeln erfüllt sind, d.h. die Zugehörigkeitsfunktion der unscharfen Regeln-Schlussfolgerungen "finanziell gesund" mit den drei Fragmenten unterdurchschnittlich, durchschnittlich und überdurchschnittlich werden nur proportional zum Erfüllungsgrad der jeweiligen Regel als zutreffend angesehen.

Zusammenfassung aller Regeln

Da meistens also mehr als eine Regel zutrifft, müssen diese zu einem Gesamturteil zusammengefasst werden. Hierfür existieren verschiedene Methoden

(Inferenzmechanismen). Die zwei gebräuchlichsten sind: die **Max-Prod-** und die **Max-Min-Inferenz** (von ALTROCK, 1997, S. 193).

Theoretischen Hintergrund Max-Prod- und Max-Min-Inferenz

Die Fuzzy Regel wird als unscharfe Relation R auf $X_1 \times X_2 \times Y$ interpretiert und die unscharfen Eingabewerte $x = (x_1, x_2)$ als unscharfe Relation S auf $X_1 \times X_2$. Die gewünschte gleichzeitige Gültigkeit von R und S erlaubt die Anwendung der Verkettungsregel für unscharfe Relationen, um das unscharfe Ergebnis B' zu berechnen:

$$B' = R \circ A'$$

Die Verkettung unscharfer Relationen ist folgendermaßen definiert (BOTHE, 1998, S.32):

Definition

Es sei $R \in P(X \times Y)$ und $S \in P(Y \times Z)$ zwei unscharfe Relationen zwischen x, y und y, z . Dann stellt die Verkettung $R \circ S$ eine unscharfe Relation auf $X \times Z$ zwischen x, z her gemäß:

$$R \circ S: m_{R \circ S}(x, z) = \bigvee_y [m_R(x, y) \wedge m_S(y, z)]$$

Speziell für $\bigvee_y = \max_{y \in Y} [\cdot]$ und $\wedge = \min[\cdot]$ handelt es sich um eine max-min-Verkettung. Die Maximumbildung wird verwendet, da mehrere mögliche Werte y ein erfolgreiches Abbilden von x -Werten auf z -Werte ermöglichen können.

Wenn \wedge mit Hilfe des algebraischen Produkts (\cdot) dargestellt wird, entsteht die Max-Prod-Verkettung

$$R \circ S: m_{R \circ S}(x, z) = \bigvee_y [m_R(x, y) \cdot m_S(y, z)]$$

Es sei $R \in P(X \times Y)$ und $S \in P(Y \times Z)$ zwei unscharfe Relationen zwischen jeweils abzählbar vielen Elementen. Dann kann die Verkettung von $R \circ S$ als Matrizenoperation dargestellt werden. Die Max-Min-Verkettung kann beispielsweise nach dem Schema der gewöhnlichen Matrizenmultiplikation berechnet werden, wobei die Multiplikation durch Minimumbildung und die Addition durch Maximumbildung zu ersetzen sind.

Die einfachste Methode zur Bestimmung der unscharfen Relation R aus den unscharfen Parametern A_1, A_2 und B der Regel besteht in der Anwendung des unscharfen kartesischen Produkts als größtmögliche unscharfe Relation. Hierbei handelt es sich um die *Max-Min-Inferenzmethode*.

Wegen der konjunktiven Verknüpfung von x_1 und x_2 im Bedingungsteil der Regel ergibt sich R als Durchschnitt zweier unscharfer Relationen R_1 und R_2 zu:

$$R = R^1 \cap R^2 = (A_1 \otimes B) \cap (A_2 \otimes B)$$

Die Zugehörigkeit zu B' berechnet sich mit Hilfe der *Max-Min-Verkettungsregel* zu:

$$\begin{aligned} \mu_B(y) &= \max_{x \in X} \min[\mu_R(x_1, x_2, y), \mu_{a_1}(x), \mu_{a_2}(x)] = \\ &= \max_{x \in X} \min[\mu_{A_1}(x), \mu_{A_2}(x), \mu_B(x), \mu_{a_1}(x), \mu_{a_2}(x)] = \\ &= \min[\mu_{A_1}(a_1), \mu_{A_2}(a_2), \mu_B(y)] \end{aligned}$$

Der Wert $\beta = \min[\mu_{A_1}(a_1), \mu_{A_2}(a_2)]$ repräsentiert den Aktivierungsgrad β der Regel durch den aktuellen Eingangswertevektor (a_1, a_2) in einer im allgemeinen nichtlinearen Form.


Bei der *Max-Prod-Inferenzmethode* wird das kartesische Produkt zwischen A_1 und A_2 durch Minimumbildung und das mit B durch Multiplikation berechnet:

$$\mu_B(y) = \max_{i, x \in X} [\beta_i \cdot \mu_{B_i}(y)]$$


Unterschiedliche Darstellung der Max-Prod- und der Max-Min-Inferenz

Bei der *Max-Prod-Inferenz* wird der Erfüllungsgrad der Regeln mit der Zugehörigkeitsfunktion der entsprechenden unscharfen Menge der Zielgröße multipliziert, so dass sich graphisch für alle Erfüllungsgrade <1 eine gestauchte Zugehörigkeitsfunktion ergibt. (vgl. den grauen Bereich in 9)9)

ABB. 37: MAX-PROD-INFERENZ



Quelle: Eigene Darstellung


ABB. 38: MAX-MIN-INFERENZ

Quelle: Eigene Darstellung

Alternativ kann auch die rechnerisch einfachere Max-Min-Inferenz gewählt werden, bei der die Zugehörigkeitsfunktionen der Regel-Konsequenzen nicht prozentual verkleinert wird, sondern in Höhe des Zugehörigkeitsgrades „glatt“ abgeschnitten wird (vgl. ROMMELFANGER, 1988). Beide Inferenzen unterscheiden sich im Ergebnis nur wenig, wobei die Max-Min-Inferenz niedrigere und mittlere Erfüllungsgrade stärker gewichtet (ROMMELFANGER, 1991, S. 41).

Gewichtung mehrerer Zugehörigkeiten zu einem Fragment

Es können gleichzeitig mehrere Regeln für ein Fragment zutreffen (vgl. Tab. 4). In diesem Fall weist eine durchschnittliche finanzielle Gesundheit zwei positive Regeln auf. Die Abb. 39 stellt diese Zugehörigkeiten dar.

ABB. 39: UNSCHARFE SCHLUSSFOLGERUNG FÜR DIE "FINANZIELLE GESUNDHEIT"

Quelle: Eigene Darstellung

Für die Berechnung eines gesamten Erfüllungsgrad kann nicht nur die maximale Zugehörigkeit in die Gesamtbeurteilung mit eingehen (d.h. $\max(0,25; 0,16) = 0,25$).

Diese Berechnung ist unzureichend, da auf diese Weise Regelwissen unterschlagen wird, und die Gewichtung der einzelnen Bewertungen ein falsches Bild gibt. Andererseits scheint es auch nicht sinnvoll zu sein, die Erfüllungsgerade gleicher Beurteilungen einfach zu addieren, da der Mensch bei einem mehrfachen Auftreten der gleichen (unscharfen) Informationen sicher nur einen abnehmenden Grenznutzen des Informationszuwachses annimmt (SCHEFFELS, 1996, S.88). Andernfalls würden zwei Regeln, die einem Zugehörigkeitswert von je $< 0,5$ die Bewertung < 1 für diese Menge zuordnen, also einen höheren Wert als eine voll zutreffende Regel. Empirische Untersuchungen haben ergeben, dass das menschliche Entscheidungsverhalten recht gut mit der algebraischen Summe

$$DOF_{\text{Bewertung}} = \left[1 - \prod (1 - DOF_{\text{Regel } i}) \right]$$

abgebildet werden kann (vgl. ROMMELFANGER, 1988). Hierbei ist DOF (Degree of Fulfillment) der Erfüllungsgrad der Regel.

Ergebnis der Inferenz

Das Ergebnis der Inferenz ist eine Fläche mit der Ausgangs-Fuzzy Menge, welche sich über alle Bereiche erstrecken kann, und deren Höhe von den Erfüllungen der einzelnen Regeln abhängt. Die hier dargestellte Größe ist eine Fuzzy-Größe (vgl. Abb. 39). Das Ergebnis der Inferenz ist die Fläche unter den Zugehörigkeitsfunktionen.

Der Vorteil von Fuzzy-Inferenz besteht in der grobkörnigen Natur der Inferenzregeln. In vielen Fällen sind nur wenige Regeln notwendig, um ein Problem zu modellieren (ROJAS, 1996, S.239). Jede Regel ordnet dem unscharfen Eingangswert einen unscharfen Ausgangswert zu. Im Raum der Ein- und Ausgangswerte entstehen Gebiete, innerhalb deren die Punkte mehr oder weniger stark zu den Regeln gehören. Das sind die sogenannten unscharfen Punkte. Die Aneinanderreihung ineinandergreifender unscharfer Punkte bestimmt den Kurvenzug der approximierenden Funktion.

3.5.5 Defuzzifizierung

Soll die von dem Inferenzmechanismus erzeugte Fuzzy-Größe einen eindeutigen Wert annehmen, so muss diese Größe defuzzifiziert werden. Scharfe Zahlen lassen sich kanonisch in Fuzzy Zahlen einbetten, soll aber umgekehrt eine Fuzzy Zahl in eine scharfe Zahl überführt werden, muss sie defuzzifiziert werden. Hierbei treten einige Probleme auf.

Maximum-Methode

Für diesen Schritt kommen verschiedene je nach Problemstellung geeignete Verfahren in Frage (ZIMMERMANN, 1993, S.100ff.). Das einfachste Defuzzifizierungsverfahren stellt die *Maximum-Methode* dar. Hier wird ein Punkt auf der Zugehörigkeitsfunktion

gewählt, der den maximalen Zugehörigkeitsgrad annimmt. Problematisch wirkt sich hierbei allerdings aus, dass hierfür mehrere Werte existieren können. Wird allerdings ein Punkt aus dieser Menge zufällig ausgewählt, führt dies zu Nichtdeterminismus des Reglers. Um dies zu vermeiden wird beispielsweise die kleinste oder die größte Zahl ausgewählt, für die der Zugehörigkeitswert am größten ist.

Flächenschwerpunktmethode


Die aufwendigste ist die *Flächenschwerpunktmethode (Center-of-Gravity-Methode)*, bei dem der Flächenschwerpunkt der unscharfen Lösungsmenge den "scharfen" Ausgabewert bestimmt. Sie hat den Vorteil, dass fast immer ein relativ glattes Regelverhalten erzeugt wird. Die Nachteile bestehen darin, dass dieses Verfahren formal aus der Sicht der Fuzzy Systeme kaum zu rechtfertigen und sehr aufwendig zu berechnen sind (KRUSE et al., 1993).

Sie berechnet sich folgendermaßen:

$$y = \frac{\int \mu_B(y) y dy}{\int \mu_B(y) dy}$$

Diese Methode tendiert zu einem guten statistischen Verhalten und wird bei sehr unterschiedlichen Anwendungen eingesetzt. Die Auswirkungen von kleineren Störungen oder Variationen der Zugehörigkeitsfunktion werden durch die Integration abgeschwächt.

Abb. 40: Flächenschwerpunktmethode



Quelle: Eigene Darstellung

Um einen scharfen Wert der "finanziellen Gefährdung" zu erhalten, kann der Schwerpunkt der grauen Fläche gebildet werden und auf die horizontale Achse (y) gelotet werden.

Beispiel für Schwerpunktmethode

Für das Beispiel der Diagnose des finanziellen Zustandes kann eine Defuzzifizierung mit der Schwerpunktmethode einen scharfen Wert erzeugen. Dieser Wert gibt an, wie die finanzielle Gesundheit des Unternehmens ist. Bei der vorgegeben Skala von 1 bis 5 weist das Beispielsunternehmen einen Wert von 3,7 Punkte aus. Dieser Wert besagt, dass das Unternehmen über eine überdurchschnittliche finanzielle Gesundheit verfügt.

Mittelwert-Max-Methode

Eine weitere Methode ist die *Mittelwert-Max-Methode*, bei dem der Wert als "scharfe" Ausgabegröße gilt, der die Fuzzy Menge in zwei gleich große Hälften teilt. Mit Hilfe der Flächenhalbierungsverfahren können unscharfe Beurteilungsmengen auf einen Wert verdichtet werden.

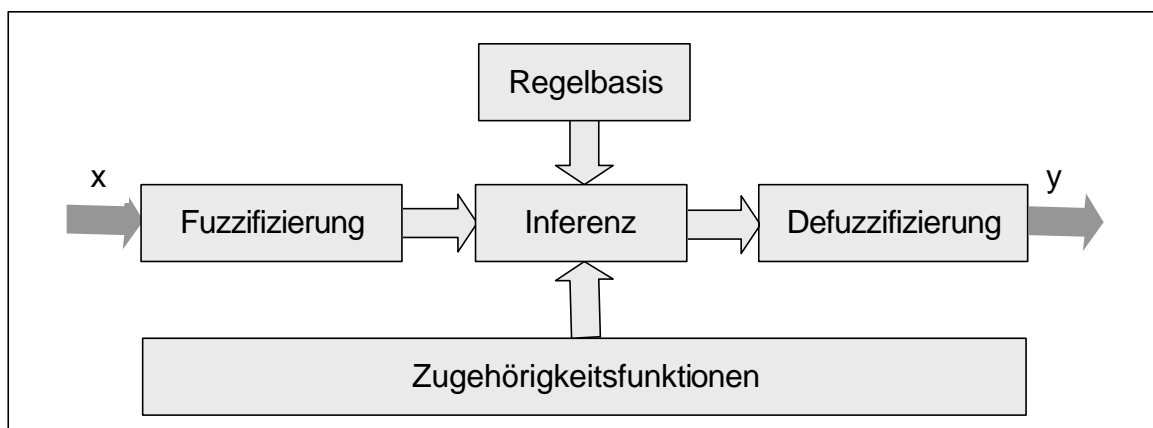
3.5.6 Fazit

Durch den grundlegenden Artikel "Fuzzy Sets" von ZADEH (1965) etablierten sich die FS sowohl in den technischen wie auch in den ökonomischen Forschungs- und Anwendungsbereichen. Mit Hilfe der FS ist es möglich unscharfes Wissen zu verarbeiten. Es ist kein mathematisches Modell für die FS notwendig. Die Verarbeitung des unscharfen Wissen erfolgt über Wenn - Dann - Regeln.

Die FS haben folgenden Aufbau:

- *Fuzzifizierung*
- *Inferenz* in drei Schritte:
 - Auswertung der Prämissen aller Regel (Aggregation)
 - Auswertung der Konklusion (Implikation)
 - Zusammenfassung der Regeln (Akkumulation)
- *Defuzzifizierung*

ABB. 41: AUFBAU EINES FUZZY SYSTEMS (FS)



Quelle: Eigene Darstellung

Zur *Fuzzifizierung*: Die Input-Variablen werden in Zugehörigkeiten von unscharfen Mengen durch Zugehörigkeitsfunktionen zugeordnet. Als erstes werden die linguistischen Variablen und ihre zugehörigen "Fuzzy Mengen" definiert.

Zur *Inferenz*: Anschließend werden die Fuzzy-Inferenzregeln, die aus einer Wissensbasis gewonnen oder zusammen mit einem Experten entwickelt werden, festgelegt. Diese Regeln sollen für ein einfaches Umsetzen idealerweise in der Form der "Wenn... Dann... -Regeln" vorliegen. Bei der Aggregation werden die in den Regeln benutzten Verknüpfungen der Eingangsgrößen entsprechend den definierten Operatoren ausgewertet, so dass ein Fuzzy-Wert für die zutreffende Regel berechnet wird.

Die Inferenz wird in den oben genannten drei Schritten unterteilt:

1. Auswertung der Prämissen aller Regeln (Aggregation):

In diesem Schritt werden die in den Regeln benutzten Verknüpfungen der Eingangsgrößen entsprechend den definierten Operatoren ausgewertet, so dass ein Fuzzy-Wert für das Zutreffen der Prämisse errechnet wird.

2. Auswertung der Konklusion (Implikation)

In der klassischen Logik ist das logische Schließen sehr einfach: Trifft die Bedingung einer Regel zu, so trifft ihre Schlussfolgerung zu; trifft die Bedingung nicht zu, dann trifft auch die Schlussfolgerung nicht zu. In der Fuzzy Logik kann eine Bedingung jedoch auch zum Teil zutreffen, so dass definiert werden muss, in welchem Umfang dann die entsprechenden Konklusion zutrifft. Ein mögliches Verfahren ist das Minimum-Verfahren, welches als Erfüllungsgrad der Schlussfolgerung das Minimum aus der Erfüllung der Prämisse und der Konklusion annimmt. Ein anderes Verfahren ist das Produkt-Verfahren, bei dem jeder Abszissenwert der Ausgangs-Fuzzy Menge mit dem Erfüllungsgrad der Prämisse multipliziert wird.

3. Zusammenfassung aller Regeln (Akkumulation)

Im letzten Schritt müssen die Konklusionen aller Regeln zusammengefasst werden, da meistens mehr als eine Regel zutrifft. Da die Regeln in den meisten Fällen über eine ODER-Verknüpfung verbunden sind, wird hier in der Regel der Maximum-Operator zur Überlagerung aller Konklusionen genutzt.

Wird für die Implikation das Minimum-Verfahren angewandt und für die Akkumulation der Maximum-Operator, dann handelt es sich hierbei um den Max-Min-Inferenzmechanismus. Wird statt des Maximum-Operator für die Implikation der Produkt-Operator verwendet, dann handelt es sich um den Max-Prod-Inferenzmechanismus.

Zur *Defuzzifizierung*: Im letzten Schritt werden die Zugehörigkeiten wieder in eine eindeutige Zahl umgewandelt.

Bei den FS existieren eine hohe Anzahl an Freiheitsgraden, die auf das Ergebnis eine große Wirkung haben, und daher vom Entwickler geeignet berücksichtigt werden müssen. Dazu zählt die Festlegung der Fuzzy Mengen, für die es eine enorme Anzahl an möglicher Realisierung gibt. Genauso wichtig ist die Festlegung der Operatoren für die Verknüpfungen, der Inferenzmechanismus und die Defuzzifizierungsmethode.

3.6 Kombination Neuronaler Netze und Fuzzy Systeme

Neuronale Netze und Fuzzy Systeme weisen als Methode unterschiedliche Vor- und Nachteile auf. Welche dieser Methoden für ein gegebenes System sinnvoll ist, muss in Abhängigkeit von ihren Eigenschaften, dem Wissen und den Gegebenheiten des zugrundeliegenden Systems entschieden werden.

Ein NN ist in der Lage, aus Beispieldaten zu lernen (vgl. Abb. 42). Der Einsatz ist immer dann möglich, wenn kein mathematisches Modell vorliegt oder dessen Umsetzung aufgrund hoher Kosten vermieden werden soll. Ein NN ist demnach grundsätzlich in der Lage, vollständig unbekannte Systeme zu beherrschen, soweit deren Eingabe- und Ausgabeverhalten bekannt sind. Nachteile von NN sind (vgl. Abb. 42), dass kein verfügbares Wissen verwendbar, die Einstellung der Netzparameter schwierig und keine inhaltliche Interpretation der Ergebnisse aufgrund des Black-Box Verhalten möglich ist.

Beim FS kann Wissen in Form linguistischer Regeln verwendet werden (vgl. Abb. 42). Ist das Wissen unvollständig, falsch oder widersprüchlich, vermag das FS seine Aufgabe nicht zu erfüllen. Die Messgrößen müssen linguistisch beschrieben werden. Durch die Verwendung linguistischer Regeln kann ein FS einfach interpretiert und implementiert werden (Abb. 42). Ohne Regelwissen können FS nicht erstellt werden.

Die aufgeführten Vor- und Nachteile (vgl. Abb. 42) der NN und FS ergänzen sich insofern, dass NN lernfähig sind und kein Regelwissen vorliegen muss bzw. dass FS Regelwissen nutzen können und einfach interpretierbar sind. Aufgrund ihrer Ergänzungen wird eine Kombination von NN und FS in einer vielfältigen Form vorgenommen (NAUCK et al., 1994, S.259). In dieser Untersuchung wird der Ansatz, dass die Eingaben eines FS durch ein NN vorverarbeitet werden können, umgesetzt. Derartige Kombinationen haben das Ziel die Ergebnisse des Gesamtsystems zu verbessern. Ein Lernvorgang findet nur in den eingesetzten NN statt, das Fuzzy System bleibt dabei unverändert. Im Gegensatz zu einem reinen NN bietet die Verwendung eines zugrundeliegenden FS den Vorteil einer schnellen Realisierung unter der Verwendung von a-priori Wissen.

ABB. 42: VOR- UND NACHTEILE DER NN UND DER FS

Neuronale Netze	Fuzzy Systeme
Vorteile	
<ul style="list-style-type: none"> ➤ Kein mathematisches Modell notwendig ➤ Kein Regelwissen notwendig ➤ Verschiedene Lernalgorithmen 	<ul style="list-style-type: none"> ➤ Kein mathematisches Modell notwendig ➤ A-priori- (Regel-)Wissen nutzbar ➤ Einfache Interpretation und Implementation
Nachteile	
<ul style="list-style-type: none"> ➤ Black-Box Verhalten ➤ Kein Regelwissen extrahierbar ➤ Heuristische Wahl der Netzparameter ➤ Anpassung an veränderte Parameter ist eventuell schwierig und erfordert die Wiederholung des Lernvorganges ➤ Kein a-piori Wissen verwendbar ➤ Der Lernvorgang konvergiert nicht garantiert 	<ul style="list-style-type: none"> ➤ Regelwissen muss verfügbar sein ➤ Nicht lernfähig ➤ Anpassung an veränderte Parameter eventuell schwierig

Quelle: NAUCK et al., 1994, S.257

4 Modellentwicklung eines Fuzzy Neuronalen-Netzes (FNN-Modell)

In Kapitel 3 sind die Instrumente NN und FS und die Vorteilhaftigkeit ihrer Kombination beschrieben worden. In Kapitel 4 werden die beiden Instrumente für den praktischen Einsatz einer empirisch-statistischen Jahresabschlussanalyse für landwirtschaftliche Unternehmen entwickelt.

Die Datengrundlage für dieses Modell sind landwirtschaftliche Jahresabschlüsse. Für empirisch-induktive Verfahren, wie das FNN-Modell, haben die verwendeten Daten einen bedeutenden Einfluss auf die Leistungsfähigkeit dieser Modelle. Aus diesem Grund wird die Datengrundlage und die Auswahl der verwendeten Variablen ausführlich beschrieben.

Anschließend wird die Entwicklung des FNN-Modells dargestellt. Es untergliedert sich in die Teilbereiche NN und FS. Beide Instrumente werden unabhängig voneinander entwickelt, aber es existieren Schnittstellen zwischen dem NN und dem FS. Das NN verwendet als Trainings-Output-Menge Daten aus dem FS. Die Output-Variablen aus der gelernten Menge des NN sind wiederum die Ausgangsdaten für ein weiteres FS.

Das Ergebnis dieses FNN-Modells ist die Klassifizierung der Jahresabschlüsse in verschiedene Klassen. Anhand dieser Klasseneinteilung kann die zukünftige finanzielle Entwicklung der landwirtschaftlichen Unternehmen abgelesen werden.

4.1 Beschreibung des zugrundeliegenden Datenmaterials

4.1.1 Allgemeine Ausführungen

Die Beschaffenheit der Datengrundlage beeinflusst die Güte der empirischen Untersuchung im besonderen Maße, da es sich bei diesem Modell um einen "Black Box Ansatz" handelt und nur geringes Vorwissen über eine Theorie vorliegt. Entsprechend diesen Anforderungen müssen die Daten für dieses Modell ausgesucht und aufbereitet werden.

Die Daten der Grundgesamtheit sind aus den betriebswirtschaftlichen Jahresabschlüssen von landwirtschaftlichen Unternehmen, die von der LAND-DATA zur Verfügung gestellt worden sind, entnommen. Als führendes Auswertungszentrum für landwirtschaftliche Jahresabschlüsse verfügt diese über ca. 60.000 Jahresabschlüsse pro Jahr, die sich über Gesamtdeutschland verteilen. Die Rohdaten, die zur Verfügung gestellt worden sind, enthalten Jahresabschlüsse von landwirtschaftlichen Haupt- und Nebenerwerbsbetrieben, Personengesellschaften und Agrargenossenschaften.

Die Datengrundlage wird bei den landwirtschaftlichen Unternehmen per Laptop erfasst. Sie wird danach bei der außerbetrieblichen Buchführung (vgl. Kapitel 2.1.2)

durch einheitlich ausgebildete Datenerfasser aufgenommen. Nach der Erfassung werden alle Datensätze in den jeweiligen Buchstellen auf Vollständigkeit und Richtigkeit überprüft. Falls erforderlich werden die Grundsatzaufzeichnungen ergänzt und aufgetretene Fehler berichtigt. Durch diese ständige Überwachung der Grundsatzaufzeichnungen in den Unternehmen ist eine einwandfreie Datenerfassung sichergestellt (LANDDATA, 1996).

Die Grundsatzaufzeichnungen werden auf Datenträger abgelegt und der Datenverarbeitung übergeben. Mit Hilfe von Plausibilitätskontrollen und Fehlerprotokollen werden die Datenbestände überwacht und mit Hilfe der elektronischen Datenverarbeitung auf Vollständigkeit und Richtigkeit überprüft. Nach diesen Vorkontrollen werden die Jahresabschlüsse in die Statistikdatei eingelesen (LANDDATA, 1996). Durch diese einheitliche Erfassung und Verarbeitung der einzelnen Kennzahlen können die Jahresabschlüsse für gemeinsame Auswertungen verwendet werden.

Ausgangsdaten für das FNN-Modell

Bei dem vorliegenden FNN-Modell handelt es sich um überwachtes Lernen. Aus diesem Grund müssen sowohl Input- wie auch Output-Daten vorliegen. Da für dieses Modell eine Klassifizierung der Unternehmen für die Entwicklung in drei Jahren vorgenommen werden soll, müssen neben den Input-Daten die Output-Daten derselben Unternehmen aus den Jahresabschlüssen entnommen werden, die zeitlich drei Jahre nach den Jahresschlüssen liegen.

Des Weiteren treten zwischen den Jahresabschlüssen größere Schwankungen bei den einzelnen Kennzahlen auf. Um den jährlichen Schwankungen entgegenzutreten ist die Bildung von 3jährigen Durchschnitten für die Kennzahlen vom Vorteil, damit das FNN die Datenstruktur besser lernen kann. Dafür müssen die Jahresabschlüsse aus den Wirtschaftsjahren 1991/92, 92/93, 93/94 und 96/97 vorliegen. Unternehmen, die in einem dieser Wirtschaftsjahre keinen Abschluss vorliegen haben, sind als Trainingsdaten für das FNN nicht geeignet.

Da mehrere Wirtschaftsjahre in das Modell eingehen, müssen die Daten aufeinanderfolgender Wirtschaftsjahre vorliegen und konsistent sein. Zu einer oftmals auftretenden Abweichung kommt es, wenn die aus der Gewinn- und Verlustrechnung (GuV-Rechnung) ermittelte Eigenkapitalveränderung nicht mit der aus der Bilanz errechneten Eigenkapitalveränderung übereinstimmt. Daher werden nur solche Unternehmen zum Training der NN einbezogen, bei denen GuV-Rechnung und Bilanz zu konsistenten Ergebnissen führen.

Da nicht von allen Unternehmen in jedem Wirtschaftsjahr alle Variablen zur Verfügung gestellt werden können, bleiben bei einer Plausibilitätskontrolle 10.034

Jahresabschlüsse, die die oben genannten Bedingungen erfüllen, übrig und können als Datengrundlage für das FNN verwendet werden.

Problem der Datenbereitstellung durch die Umstellung des Jahresabschlusses

Durch die Umstellung des landwirtschaftlichen Jahresabschlusses von dem sogenannten "Ertl-Jahresabschluss" auf den "neuen BML-Jahresabschluss" (vgl. MANTHEY, 1995) ist es nicht möglich, Daten aus beiden unterschiedlichen Jahresabschlüssen gleichzeitig für dieses Modell zu verwenden. Durch die neuen Anforderungen (Gültigkeit für alle Rechtsformen) an den "BML-Jahresabschluss" (vgl. MANTHEY, 1995) ist der alte Jahresabschluss so weit abgewandelt worden, dass beide nicht mehr direkt miteinander vergleichbar sind und der neue Jahresabschluss nicht aus dem alten Ertl-Jahresabschluss abgeleitet werden kann. Auch die Datengrundlage für die Bildung der betriebswirtschaftlichen Kennzahlen hat sich hierdurch geändert, so dass eine neue Definition der einzelnen betriebswirtschaftlichen Kennzahlen erfolgt ist (vgl. ARBEITEN DER DLG, 1997).

Wegen der Umstellung des Jahresabschlusses und der notwendigen Datengrundlage von mindestens sechs Jahren ist als Datengrundlage für dieses Modell der alte "Ertl-Jahresabschluss" verwendet worden. Da für diesen Abschluss keine Vergleichbarkeit der Einzelunternehmen mit den der Personengesellschaften und juristischen Personen gegeben ist, werden in der Datengrundlage nur Einzelunternehmen berücksichtigt.

4.1.2 Dateneinteilung

Die Kennzahlen für die einzelnen Betriebstypen unterscheiden sich voneinander. Beispielsweise ist die Umsatzrentabilität für einen Milchviehbetrieb im Durchschnitt wesentlich höher als die für einen Veredelungsbetrieb. Ein sinnvoller Vergleich von Unternehmen setzt voraus, dass die betrieblichen Sachverhalte vergleichbar sind (GRÄFER, 1990, S.63f.). Diese Voraussetzung liegt bei den unterschiedlichen Betriebstypen nicht vor.

Daher erfolgt eine Einteilung der Daten nach Marktfrucht-, Futterbau-, Veredelungs- und Gemischtbetriebe (Tab. 5).

TAB. 5: AUFTEILUNG DER UNTERNEHMEN

Betriebstyp	Marktfrucht	Futterbau	Veredelung	Gemischt
Anzahl der Jahresabschlüsse	1.642	5.398	2.109	885

Quelle: Buchführungsdaten der LAND-DATA

Aus Vergleichbarkeitsgründen ist es sinnvoll, für die einzelnen Betriebstypen jeweils ein eigenes FNN-Modell zu trainieren. In dieser Arbeit ist ein FNN-Modell beispielhaft für die Menge des Futterbaus entwickelt worden. Für den weiteren Verlauf der Arbeit handelt es sich dementsprechend bei der Datengrundlage um die Teilmenge der Futterbaubetriebe.

Des Weiteren werden die Datensätze in Lern-, Validierungs- und Testmenge unterteilt (vgl. Kapitel 3.4.9). Mit Hilfe einer Auswahl von Datensätzen, der Lernstichprobe, werden die NN trainiert. Um dem Problem des Überlernens zu begegnen, muss beim NN von der Lernstichprobe eine Teilmenge als Validierungsmenge abgetrennt werden. Überlernen bedeutet, dass ein NN zwar die Lernstichprobe gut klassifiziert, aber bei der Übertragung auf die Testmenge schlechtere Ergebnisse liefert (vgl. Kapitel 3.4.9).

Es gibt keine Untersuchungen darüber, welche Aufteilung der Datenmenge in die einzelnen Teilmengen am effektivsten ist. Da bisher bei den meisten bisherigen Untersuchungen mit einer Validierungsmenge von 15 % gute Ergebnisse erzielt worden sind (KERLING und PODDIG, 1994, S.438), und da eine ausreichend große absolute Datenmenge von 5.398 Datensätzen zur Verfügung steht, wäre ein 15prozentiger Anteil mit 810 Datensätzen ausreichend. Als Testmenge dient später ein weiterer 15prozentiger Anteil der Gesamtmenge. Entsprechend ergibt sich folgende Datenverteilung:

TAB. 6: DATENVERTEILUNG

	Lernmenge	Validierungsmenge	Testmenge
Relativ	70 %	15 %	15 %
Anzahl der Datensätze	3.778	810	810

Quelle: Eigene Berechnungen

4.1.3 Die Struktur der ausgewählten Buchführungsdaten

Zur besseren Darstellung der Datengrundlage und der verwendeten Unternehmen sind in der folgenden Tab. 7 der arithmetische Mittelwert, Standardabweichung, die Schiefe und der Exzess für die jeweiligen absoluten Grundkennziffern aus den Jahresabschlüssen 1991/92, 92/93 und 93/94 der im Modell verwendeten Unternehmen aufgeführt.

TAB. 7: VERTEILUNGSMASSE DER ABSOLUTEN KENNZAHLEN (AUSZUG)

Wirtschaftsjahr 91/92, 92/93, 93/94	Einheit	arithmetischer Mittelwert	Standard- abweichung	Schiefe	Exzess
Eigenkapital	DM je Unternehmen	1.020.054	669.108	0,96	1,84
Fremdkapital gesamt	DM je Unternehmen	187.690	168.959	2,02	8,08
Fremdkapital kurzfristig	DM je Unternehmen	46.441	66.724	5,75	65,79
Bilanzsumme	DM je Unternehmen	1.207.744	783.459	0,99	1,84
Grund und Boden	DM je Unternehmen	837.534	775.733	0,95	1,70
Brutto- investitionen	DM je Unternehmen	63.012	125.865	7,15	66,38
LF	ha je Unternehmen	42,5	20,7	1,61	5,43
Unternehmens- ertrag	DM je Unternehmen	242.184	180.548	1,47	3,64
Unternehmens- aufwand	DM je Unternehmen	196.928	158.779	1,42	2,52
Gewinn	DM je Unternehmen	45.256	50.311	4,18	33,51

Quelle: Buchführungsdaten der LAND-DATA, eigene Berechnungen

Die hier ausgewiesenen durchschnittlichen Werte für die jeweilige Position entsprechen weitestgehend den Werten aus dem Situationsbericht des Deutschen Bauernverbandes und dem Agrarbericht des BMELF. Diese Durchschnittswerte sagen aber noch nicht viel über die Verteilung der jeweiligen Werte aus.

Die Lagemaße von Häufigkeitsverteilungen, wie der "arithmetische Mittelwert", geben allein wenig Auskunft über die Häufigkeitsverteilung. Zusätzlich werden deshalb die Maße, die die Abweichung von einem Zentrum einer Häufigkeitsverteilung angeben, die sogenannten Streuungsmasse oder Dispersionsmaße, aufgeführt. Anhand der Lage- und Streuungsmasse kann man sich ein recht präzises Bild über die Verteilung der jeweiligen Kennzahl machen (HARTUNG, 1998, S. 41).

Um die Verteilung der Kennzahlen besser darzustellen, werden die beiden Verteilungsmasse Schiefe und Exzess ausgewertet: Die *Schiefe* ist eine Bezeichnung für die Abweichung einer Häufigkeitsverteilung von der symmetrischen Verteilung, also

von der Verteilung, bei der innerhalb gleicher Abstände vom Mittelwert auf beiden Seiten jeweils gleich viele Werte liegen. Die Schiefe ist null, wenn die beobachtete Verteilung eine Normalverteilung ist. Je stärker der Wert der Schiefe negativ ist, desto linksschiefer ist die Verteilung, und sie ist umso rechtsschiefer, je stärker positiv der Wert der Schiefe ist. Der *Exzess* gibt die Steilheit einer Verteilung an. Er ist Null, wenn die beobachtete Verteilung eine Normalverteilung ist. Ist der Wert des Exzesses größer als Null, so ist das absolute Maximum der Häufigkeitsverteilung größer als das der zugehörigen Normalverteilung; ist der Wert des Exzesses kleiner als Null, so ist es kleiner.

Die *Standardabweichung* ist die Quadratwurzel aus der Varianz. Diese berechnet sich aus der Summe der Abweichungsquadrate aller Messwerte von ihrem arithmetisches Mittel, dividiert durch die um 1 verminderte Anzahl der Werte (BÜHL, 1996, S.104).

Bei der Ermittlung der statistischen Kennzahlen ist darauf zu achten, dass nicht alle sinnvoll interpretiert werden können. Die Kennzahl "Grund und Boden" weist eine bimodale Verteilung auf. Aufgrund einer größeren Anzahl an Pachtbetrieben in der Datenmenge ist die Verteilung zweigipflig. Bei dieser Kennzahl kann das arithmetische Mittel nicht sinnvoll interpretiert werden.

Hohe Standardabweichungen im Verhältnis zum Mittelwert - trotz 3jähriger Durchschnitte - weisen besonders die Bruttoinvestition, der Gewinn und das Fremdkapital auf (vgl. Tab. 7). Gerade in diesen Bereichen Investition, Finanzierung und Gewinn unterscheiden sich die Unternehmen besonders voneinander.

Alle Kennzahlen in Tab. 7 weisen eine rechtsschiefe Verteilung auf, d.h. die Werte der Schiefe und des Exzesses sind bei allen Kennzahlen ungleich Null. Die Werte der Schiefe für die Kennzahlen "Bruttoinvestition" und "kurzfristiges Fremdkapital" weisen besonders hohe Werte auf. Ein Grund für die rechtsschiefe Verteilungsform der "Bruttoinvestition" und "kurzfristiges Fremdkapital" ist die schubweise Investition von Unternehmen und dass "wachsende" Unternehmen prozentual schneller wachsen, als weichende Unternehmen reduzieren. Ein wachsendes Unternehmen übernimmt in der Regel die Produktionskapazität von mehreren ausscheidenden Unternehmen. Die beiden Kennzahlen "Bruttoinvestition" und "kurzfristiges Fremdkapital" weisen neben den hohen positiven Werten für die Schiefe auch hohe positive Werte für den Exzess auf. Bei diesen beiden Kennzahlen handelt es sich um eine schmalgipflige Verteilung. Die Werte für diese beiden Kennzahlen häufen sich stärker um einen Wert der Verteilung. Der Exzess ist ein weiterer Beleg für die Investitionsschübe der Unternehmen.

Die großen Unterschiede in der Ausstattung mit Fremdkapital sind darauf zurückzuführen, dass eine Fremdkapitalaufnahme häufig in Verbindung mit einer schubweisen Investition erfolgt. Außerdem gibt es bei vielen Unternehmen

unterschiedliche Investitionsfinanzierungen. Diese erfolgt entweder durch betriebseigenes Eigenkapital, durch Einlagen aus dem Privatvermögen oder durch Fremdkapital. Zusätzlich wird der Wert für das Fremdkapital nach unten hin mit dem Wert Null begrenzt. Nach oben hin unterliegt er keiner Begrenzung.

Selbst bei der Kennzahl Gewinn existiert eine rechtsschiefe Verteilungsform, weil die Extremwerte im positiven Gewinnbereich größer sind als im negativen. Die extreme Schwankungsbreite bei dem Gewinn ist darauf zurückzuführen, dass die Unternehmen sehr unterschiedlich mit nicht entlohnten Produktionsfaktoren, wie Eigenkapital, Arbeitskräfte und Quote, ausgestattet sind.

Für das spätere Training der NN ist es wichtig, dass Varianzen im zugrundeliegenden Datenmaterial existieren. Bei annähernder Gleichheit der Werte ist das NN nur schlecht in der Lage, bestimmte Muster in dem jeweiligen Jahresabschluss zu erkennen und einer bestimmten Klasse zuzuordnen. Der vorgestellte Auszug der Datengrundlage bestätigt, dass die notwendigen Varianzen vorliegen.

4.1.4 Festlegung des Kennzahlenkatalogs

Für den Aufbau eines empirisch-induktiven Modells, wie das FNN, ist die Auswahl geeigneter Variablen erforderlich. Aus der Vielzahl der vorliegenden Kennzahlen in den Jahresabschlüssen müssen die für das FNN-Modell notwendigen Variablen ausgewählt werden.

4.1.4.1 Output-Variablen

Die Erstellung der Kennzahlen soll sich an den Vorgaben der Kapitel 2.5 und 2.6 orientieren. Folgende allgemeine Kriterien müssen bei der Auswahl der Kennzahlen erfüllt werden (PYTLIK, 1995, S.234):

- Kennzahlen, die redundante Informationen enthalten (z.B. Kehrwerte), werden nicht zusätzlich mit aufgenommen.
- bei Kennzahlen, die sich inhaltlich unwesentlich voneinander unterscheiden, soll eine möglichst plausible Auswahl getroffen werden, um die Anzahl der untereinander hochkorrelierenden Kennzahlen gering zu halten.
- Kennzahlen, deren Zähler und Nenner negative Werte annehmen können, müssen ausgeschlossen werden, weil in diesem Falle der Kennzahlenwert eines Unternehmens positiv werden kann, wenn im Nenner und Zähler gleichzeitig ein negativer Wert existiert. Es kann somit zu Fehlinterpretationen kommen.

Bevor die Auswahl des Kennzahlenkatalogs für die Input-Variablen erfolgen kann, muss zunächst der Kennzahlenkatalog für die Output-Variablen erstellt werden. Danach werden erst die Input-Daten ausgewählt, die für die Bestimmung der Output-Variablen notwendig sind.

Das Ereignis, das klassifiziert werden soll, ist der **"finanzielle Zustand"** landwirtschaftlicher Unternehmen. Dieser wird in zwei verschiedenen Klassen unterteilt werden:

"finanziell gefährdet"

"finanziell gesund"

Hierbei handelt es sich um den *relativen finanziellen Zustand*. Die Kennzahlen der Unternehmen sind abhängig von externen Einflussfaktoren. Durch Preis-, Ertragsschwankungen und politischen Einflüsse können u.a. die Rentabilitäts- und Ertragskennzahlen beeinflusst werden.

In den Kennzahlen aus den Jahresabschlüssen liegen keine Informationen über diese externen Einflussfaktoren vor. Somit können die Kennwerte nicht aus vergangenheitsbezogenen Jahresabschlüssen abgeleitet werden. Die externen Einflussfaktoren beeinflussen aber alle Unternehmen. Deshalb kann der relative Output-Kennwert im Verhältnis zu den anderen Unternehmen bestimmt werden.

Aus diesen Gründen wird nicht nach den Output-Werten klassifiziert, sondern nach den relativen Output-Werten. Es wird für jedes Unternehmen die Abweichung der Kennzahl zu dem arithmetischen Mittel bestimmt. Diese Abweichung dient als Output-Wert, nach dem klassifiziert wird. Im weiteren Verlauf der Arbeit ist mit den beiden Klassen "finanziell gefährdet" und "finanziell gesund" der relative finanzielle Zustand gemeint.

4.1.4.1.1 Auswahl der Output-Variablen

Der finanzielle Zustand der landwirtschaftlichen Unternehmen kann nicht durch eine eindeutige Beobachtung in diese beiden Klassen unterteilt werden. Die Abgrenzung zwischen den beiden Klassen ist nur durch die Definition von Werten für bestimmte Kennzahlen möglich. Als erstes muss bestimmt werden, durch welche möglichen Kennzahlen dieses Ereignis repräsentiert wird.

Der finanzielle Zustand kann beschrieben werden durch Kennzahlen der Liquidität und Stabilität und unter längerfristigen Betrachtung durch die Rentabilität.

Liquidität - Kennzahl "dynamischer Verschuldungsgrad"

Mit Hilfe der Liquiditätsgrade kann ermittelt werden, ob und inwieweit die kurzfristigen Verbindlichkeiten in ihrer Höhe und Fälligkeit durch Zahlungsmittelbestände ausgeglichen werden können (KÜTING und WEBER, 1994, S.119). Bei den Liquiditätskennzahlen handelt es sich im Allgemeinen um kurzfristige Deckungsstrukturregeln. Die Ermittlung der Liquidität ist anhand der Jahresabschlussanalyse nur zu einem bestimmten Stichtag möglich. Es wird Kritik an den Kennzahlen für die Liquidität geübt, weil diese durch mögliche Bilanzpolitiken beeinflusst werden können, da die gebildeten Liquiditätskennzahlen Momentaufnahmen sind. Deshalb wird auf diese kurzfristigen Liquiditätskennzahlen zur Beschreibung dieses Ereignisses verzichtet.

Eine bessere Kennzahl für die Beurteilung der Liquidität eines Unternehmens ist der *Cash flow* (ARBEITEN DER DLG, 1997, S.26). Ein wichtiges Ziel der Ermittlung vom Cash flow ist das Ausschalten von bilanzpolitischen Einflüssen. Da der Cash flow allgemein als Einzahlungen minus Auszahlungen definiert ist (KÜTING und WEBER, 1994, S.126), spielen bei dieser Kennzahl Bestandsergänzungen und Abschreibungen keine Rolle.

Der Cash flow hat zwei Verwendungszwecke: Die Bewertung der *Finanz-* und der *Ertragskraft*. Seine Hauptfunktion ist die Ermittlung der Finanzierungskraft des Unternehmens. Aus diesem Gründen eignet sich die Kennzahl Cash flow für die Beschreibung des finanziellen Zustandes eines Unternehmens.

Da die absolute Kennzahl einen geringeren Informationsgehalt hat, soll eine Verhältniskennzahl, die den Cash flow beinhaltet, verwendet werden. Eine geeignete Kennzahl ist der *Entschuldungsgrad* (Cash flow/Fremdkapital). Diese Kennzahl gibt den Prozentsatz der Verschuldung unter ceteris paribus Bedingungen an, der in einem Jahr zurückgezahlt werden könnte (KÜTING und WEBER, 1994, S.132). Diese Kennzahl wird häufig bei der Prognose von Insolvenzen verwendet. Das Problem für die Anwendung des Entschuldungsgrads liegt in der Massenstatistik. Unternehmen, die kein Fremdkapital aufgenommen haben, müssten von der Klassifizierung ausgeschlossen werden, da eine Division durch Null nicht definiert ist. Deshalb ist der Kehrwert dieser Kennzahl, der "*dynamische Verschuldungsgrad*", als Output-Variable für diese Arbeit vorzuziehen. Dieser gibt an, wieviele Jahre das Unternehmen benötigt, um das Fremdkapital unter ceteris paribus Bedingungen zurückzuzahlen und dient somit ideal zur Beschreibung des finanziellen Zustandes des Unternehmens (ARBEITEN DER DLG, 1997, S.26). Der Fall, dass der Cash flow gleich Null wird, ist nicht ausgeschlossen, tritt aber nur sehr selten auf. Anhand einer Plausibilitätskontrolle können diese Unternehmen aus der Datengrundlage aussortiert werden.

Bei einer näheren Betrachtung der Kennzahl *dynamischer Verschuldungsgrad* stellt sich heraus, dass die statistischen Maßeinheiten arithmetisches Mittel, Standardabweichung, Schiefe und Exzess zwar die Verteilung der Werte beschreiben, aber nicht zur Interpretation des sachlogischen Inhalts dienen. Der dynamischer Verschuldungsgrad interpretiert die Anzahl der Jahre, die benötigt werden, um das Fremdkapital aus dem laufenden Cash flow zu begleichen. Um so geringer der dynamischer Verschuldungsgrad ist, desto kürzer ist der ausgewiesene Zeitraum und desto weniger finanziell gefährdet ist das Unternehmen. Hat das Unternehmen allerdings einen negativen Cash flow (5% der vorliegenden Grundgesamtheit), kennzeichnet die Kennzahl den Zeitraum, in dem sich die Schulden verdoppeln. Das Ziel eines Unternehmens ist nicht, einen möglichst großen oder kleinen dynamischen Verschuldungsgrad zu erreichen, sondern einen Wert der sich der Null annähert und gleichzeitig positiv ist. Deshalb gibt das arithmetische Mittel nicht den durchschnittlichen Zeitraum der Fremdkapitalbegleichung an.

Stabilität - Kennzahl "Fremdkapitalanteil"

Als weitere Kennzahl wird der *"Fremdkapitalanteil"* verwendet. Dieser wird in vielen credit-scoring Verfahren als Kennzahl eingesetzt (vgl. Kapitel 2.5 und BARRY et al., 2000, S.110). Der *"Fremdkapitalanteil"* ermittelt, in welcher Höhe das Fremdkapital an der Vermögensfinanzierung beteiligt ist (BODMER und HEIßENHUBER, 1993, S.284). Eine niedrige Fremdkapitalquote bedeutet eine solide Finanzierung des Unternehmens. Um so niedriger dieser Wert ist, desto besser kann das Unternehmen auf unvorhergesehene Risiken reagieren. Außerdem erleichtert eine niedrige Fremdkapitalquote zusätzliche Fremdkapitalaufnahmen. Hierdurch hat das Unternehmen neben der höheren finanziellen Stabilität auch größere Wachstumspotentiale.

Da sowohl das Gesamtkapital wie auch das Fremdkapital nur Werte über Null annehmen können, ist der Fremdkapitalanteil immer größer als Null. 14 % der Unternehmen weisen hier eine Null auf und haben somit kein Fremdkapital geliehen. Weiter ist durch den Effekt des hohen Eigenlandanteils und der hieraus resultierenden niedrigen Kapitalverzinsung der geringe durchschnittliche Fremdkapitalanteil zu erklären. Weil reine Pachtbetriebe in der Datengrundlage existieren, ist die Kennzahl Fremdkapitalanteil für das Intervall von 60 bis 100 % annähernd gleichverteilt. Durch hoch verschuldete Unternehmen existieren auch Unternehmen mit einem Fremdkapitalanteil von über 100 %, d.h. diese Unternehmen (unter 1% der Gesamtmenge) haben eine Unterbilanz. Das Ziel des Unternehmers, einen hohen oder einen niedrigen Anteil an Fremdkapitalanteil zu erzielen, ist nicht eindeutig. Aus Sicherheitsgründen ist ein niedriger Fremdkapitalanteil anzustreben, aber aus Rentabilitätsgründen und somit einer langfristigen finanziellen Stabilität müsste ein hoher Fremdkapitalanteil angestrebt werden, wenn die Voraussetzungen längerfristig erfüllt sind, dass die Gesamtkapitalrentabilität höher ist als der zu zahlende Zins.

Bei der Betrachtung der optimalen Kapitalstruktur ist nicht davon auszugehen, dass eine 100prozentige Eigenkapitalfinanzierung für das Unternehmen die beste Kapitalstruktur darstellt. Bei der Frage nach der optimalen Kapitalstruktur stehen die Sicherheitsaspekte und die Rentabilität in Konkurrenz zueinander. Besonders deutlich tritt in diesem Zusammenhang der *Leverage-Effekt* (BRANDES und ODENING, 1992, S. 87f.) zutage. Dieser besagt, dass es für ein Unternehmen aus der Sicht der Rentabilität so lange sinnvoll ist, Fremdkapital aufzunehmen, wie die Gesamtkapitalrentabilität höher ist als der Zinssatz.

Rentabilität - Kennzahl "Gesamtkapitalrentabilität"

Deshalb stammt die dritte Kennzahl zur Beschreibung der finanziellen Gefährdung aus dem Bereich der Rentabilität. Bei einer langfristigen Betrachtung ist ein Unternehmen nicht finanziell gefährdet, wenn es langfristig in der Lage ist, Gewinne zu erzielen. Die Maximierung der Eigenkapitalrentabilität stellt zwar eine der wichtigsten Zielgrößen der Unternehmen dar (KÜTING und WEBER, 1994, S.294), kann aber als Output-Variable nicht verwendet werden. Diese Kennzahl stellt das Verhältnis von kalkulatorischen Gewinn zum Eigenkapital dar. Da aber Unternehmen existieren, die sowohl positives wie auch negatives Eigenkapital (Unterbilanz) aufweisen, kann es bei der Bildung der Eigenkapitalrentabilität zu gleichen Verhältniszahlen kommen, obwohl die wirtschaftliche Lage dieser Unternehmen sich sehr unterschiedlich darstellt. Beispielsweise hat ein Unternehmen mit einem Verlust von 10.000 DM und einer Unterbilanz von 1.000 DM eine Eigenkapitalrentabilität von + 1.000 Prozent. Dieses bedeutet nicht, dass dieses Unternehmen in der Zukunft nicht finanziell gefährdet ist, sondern es ist hochgradig gefährdet, weil es kein Eigenkapital aufweist und gleichzeitig hohe Verluste realisiert werden.

Außerdem kommt es bei Unternehmen mit einem geringen Eigenkapitalanteil zu hohen Schwankungen der Eigenkapitalrentabilität, da die Basis der Kennzahl für diese Unternehmen klein ist. Bei Unternehmen mit einem geringen Fremdkapitalanteil sind die Schwankungsbreiten dementsprechend geringer.

Aus den oben genannten Gründen bietet sich an, in diesem Fall die Verwendung der Gesamtkapitalrentabilität gegenüber der Eigenkapitalrentabilität zu bevorzugen, da es sich hierbei um eine anerkannte Rentabilitätskennzahl handelt (KÜTING und WEBER, 1994, S.290), aber nicht die Probleme der Eigenkapitalrentabilität aufweist. Die *Gesamtkapitalrentabilität* bringt die Fähigkeit eines Unternehmens zum Ausdruck, Gewinne zu erzielen, ohne eine Verteilung des eingesetzten Kapitals auf Eigen- und Fremdkapital vorzunehmen. Sie gibt an, wieviel Pfennig Kapitalentgelt jede investierte DM Bilanzsumme erwirtschaftet.

Die Kennzahl *Gesamtkapitalrentabilität* kann sowohl positive wie auch negative Werte annehmen, weil der kalkulatorische Gewinn plus Zinsen sowohl negativ als auch positiv

sein kann, aber das Gesamtkapital immer positiv ist. In dieser Arbeit ist das Kapital für die Berechnung der Rentabilitätskennzahlen immer ohne Grund- und Bodenvermögen aufgrund der Bewertungsprobleme berechnet (vgl. Kapitel 2.3). Es handelt sich hier im weiteren Sinne um eine Besatzkapitalrentabilität (ARBEITEN DER DLG, 1997, S.25). Im weiteren Verlauf sind die Rentabilitätskennzahlen immer auf das Besatzkapital bezogen.

Die statistische Auswertung dieser Kennzahl kann für die sachlogische Interpretation herangezogen werden. Eine hohe Gesamtkapitalrentabilität besagt, dass dieses Unternehmen rentabel wirtschaftet und somit langfristig betrieblich nicht finanziell gefährdet sein wird. Eine negative Gesamtkapitalrentabilität besagt, dass das Unternehmen keine kalkulatorischen Gewinne plus Zinsen erzielt. Dieses Unternehmen kann nicht als finanziell gesund bezeichnet werden. Aus diesen Gründen ist die Maximierung der Gesamtkapitalrentabilität anzustreben.

Somit lässt sich der finanzielle Zustand eines Unternehmens durch die drei Kennzahlen beschreiben:

dynamischer Verschuldungsgrad	$= \frac{\text{Fremdkapital}}{\text{Cash flow}}$
Fremdkapitalanteil	$= \frac{\text{Fremdkapital}}{\text{Gesamtkapital}}$
Gesamtkapitalrentabilität	$= \frac{\text{kalkulatorischer Gewinn} + \text{Zinsaufwand}}{\text{Gesamtkapital} - \text{Grund und Bodenvermögen}}$

Da die beiden Klassen des finanziellen Zustandes eines Unternehmens nicht empirisch beobachtet werden können, erfolgt die Zuordnung der Unternehmen in die jeweilige Klasse nicht über NN, sondern über ein FS. In Anlehnung an das bisherige Wissen und Zuordnungen von den Werten zu den einzelnen Klassen (credit-scoring Verfahren, vgl. Kapitel 2.5) werden die Zugehörigkeitsfunktionen für die jeweiligen Kennzahlen aufgestellt.

Eine analytische Beschreibung des finanziellen Zustandes kann aufgrund des nur vagen und unvollständigen Wissens hierüber nicht erfolgen. Die Werte der drei Output-Variablen unterliegen starken Einflüssen, die nicht nur anhand der Informationen von Jahresabschlüssen erklärt werden können. Die exakten Werte sind stark durch nicht erfasste vergangenheitsorientierte Daten, wie Markt- und Politikgeschehnisse, beeinflusst. Hierdurch sind die Einflussgrößen von zufällig schwankenden Preisen, die durch externe Markt- und/oder Politikeinflüssen bestimmt werden, von vielen Störgrößen abhängig, die nicht durch vorhandene Input-Variablen erklärt werden können. Dementsprechend kann keine exakte Intervalleinteilung für die einzelnen

Zugehörigkeitsbereiche vorgenommen werden (vgl. credit-scoring Verfahren Kapitel 2.5).

Aus diesen Gründen wird jede Output-Variable in drei verschiedene, linguistische Fragmente unterteilt. Die Zugehörigkeitsfunktion beschreibt dann den Grad der Zugehörigkeit der Unternehmen zu dem jeweiligen linguistischen Fragment.


Bei diesen linguistischen Fragmenten handelt es sich um die relative Einteilung in überdurchschnittlich, durchschnittlich und unterdurchschnittlich. Hierdurch werden die Unternehmen relativ mit ihren Mitwettbewerbern verglichen und zu diesen bewertet, unabhängig von ihrer absoluten finanziellen Situation. Das Ergebnis besagt somit nur, ob ein Unternehmen finanziell gefährdeter ist als die anderen. Hiermit wird die **relative finanzielle Gefährdung** der Unternehmen im Vergleich zu anderen Unternehmen ermittelt und nicht die Zugehörigkeit zur einer tatsächlichen finanziellen Gefährdung. Deshalb ist das Ereignis, das klassifiziert werden soll, der relative finanzielle Zustand zu den anderen Unternehmen.

4.1.4.1.2 Verteilung der Output-Variablen

In diesem Kapitel sind die Verteilungen der drei Outputvariablen näher beschrieben worden, um anschließend die Zugehörigkeitsfunktionen ermitteln zu können:

Gesamtkapitalrentabilität

ABB. 43: VERTEILUNG DER OUTPUT-VARIABLE "GESAMTKAPITALRENTABILITÄT"



Quelle: Eigene Darstellung

TAB. 8: KENNWERTE: GESAMTKAPITALRENTABILITÄT

Output-Variablen <i>W_j 96/97</i>	arithmet. Mittel	Standard- abweichung	Schiefe	Exzess
Gesamtkapitalrentabilität in Prozent	- 0,8	2,2	- 1,683	24,38

Quelle: Eigene Berechnungen

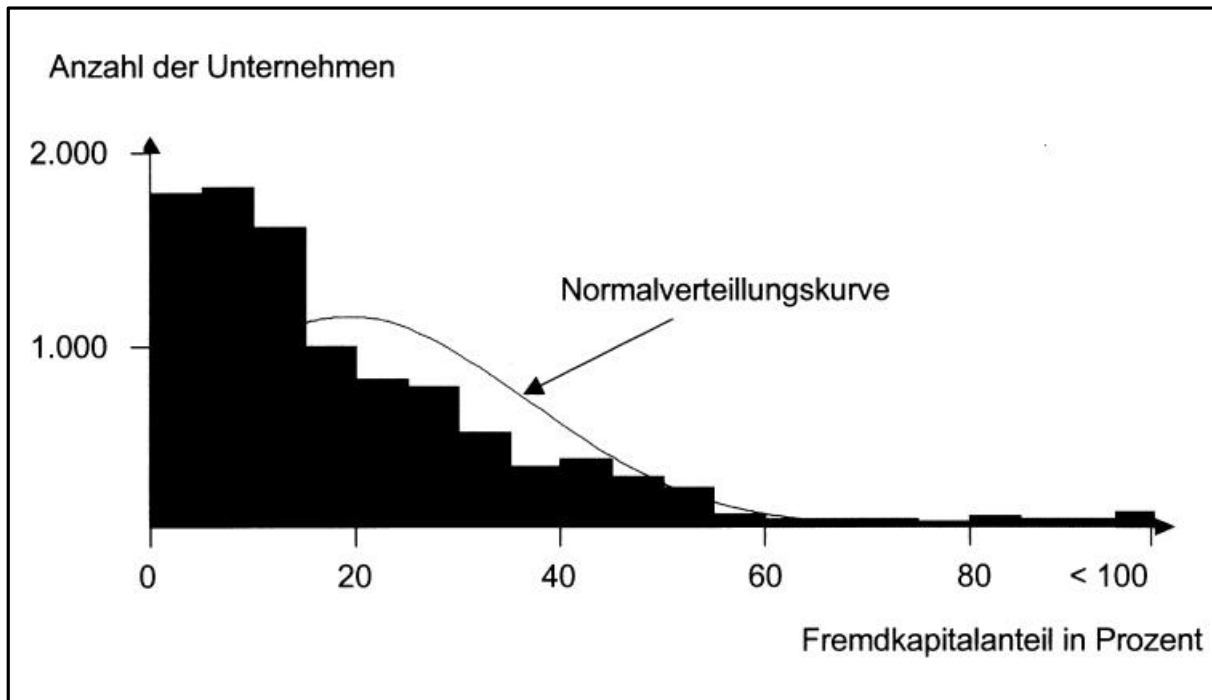
Bei der *Gesamtkapitalrentabilität* weisen 55 % aller Unternehmen eine Rentabilität zwischen -2,5% und 2,5% auf. Des weitern deutet ein Exzess von 24,38 daraufhin, dass eine große Anzahl an Unternehmen in einem kleinen Intervall liegt. Um die Probleme dieses Verteilungsverlaufes für eine spätere Klassifizierung nach dieser Kennzahl zu verdeutlichen, werden die Unternehmen in drei gleichgroße Klassen unterteilt. Die Unterteilung der Werte erfolgt in Anlehnung an die Fragmente überdurchschnittlich, durchschnittlich und unterdurchschnittlich der linguistischen Variable Gesamtkapitalrentabilität.

Zur Klasse überdurchschnittlich gehören die 33,3 % der Unternehmen mit den höchsten Gesamtkapitalrentabilitäten und zur Klasse unterdurchschnittlich die 33,3 % der Unternehmen mit den niedrigsten Gesamtkapitalrentabilitäten. Die restlichen 33,3% der Unternehmen werden der Klasse durchschnittlich zugeordnet. Die Grenze zwischen den Klassen überdurchschnittlich und durchschnittlich liegt bei dem Wert 2,68 % und für die Klassen unterdurchschnittlich und durchschnittlich bei -1,25 %.

Das Intervall von $\pm 1\%$ um die Grenze von der unterdurchschnittlichen und durchschnittlichen Menge enthält 20,8 % aller Unternehmen und das Intervall von $\pm 1\%$ um die Grenze von der durchschnittlichen und überdurchschnittlichen Menge enthält 16,6 % aller Unternehmen. Da die Klassengrenze eine sehr hohe Anzahl an Unternehmen ausweist, würde eine scharfe Abgrenzung dazu führen, dass ein NN nicht in der Lage wäre, die Datenstruktur der jeweiligen Outputklasse zu ordnen, weil viele Unternehmen mit ähnlichen Kennzahlenmuster in eine andere Klasse eingeteilt würden. Aus diesem Grund werden unscharfe Grenzen für die jeweiligen Klassen festgelegt.

Fremdkapitalanteil

ABB. 44: VERTEILUNG DER OUTPUT-VARIABLE "FREMDKAPITALANTEIL"



Quelle: Eigene Darstellung

TAB. 9: KENNWERTE: FREMDKAPITALANTEIL

Output-Variablen <i>Wj 96/97</i>	arithmet. Mittel	Standard- abweichung	Schiefe	Exzess
Fremdkapitalanteil in Prozent	18,4	17,3	2,25	9,19

Quelle: Eigene Berechnungen

Die Verteilung der Output-Variable *Fremdkapitalanteil* unterscheidet sich erheblich von der Verteilung der Gesamtkapitalrentabilität. Bei dieser Kennzahl handelt es sich um eine *Gliederungskennzahl*, da das Fremdkapital ein Teil des Gesamtkapitals ist. Hierdurch ist der untere Wert auf Null begrenzt, weil beim Fremdkapital kein negativer Wert vorliegen kann. Eine obere Grenze liegt nicht vor. Sie ist in der Grafik aus Übersichtlichkeitsgründen auf 100 % begrenzt, aber tatsächlich weisen ca. 1 % aller Unternehmen eine Unterbilanz auf. Hierdurch wird das Fremdkapital größer als 100 % des Gesamtkapitals.


Der Fremdkapitalanteil ist stark abhängig von den Eigentumsverhältnissen des Grund und Bodens. Viele Unternehmen haben einen hohen Anteil an Grund und Boden am Gesamtvermögen (66% aller Unternehmen haben einen Grund- und Bodenanteil von 50 bis 75 % am Gesamtvermögen). Da dieses Vermögen wegen der geringen Rentabilität selten durch Fremdkapital finanziert wird, verringert sich der

Fremdkapitalanteil für diese Unternehmen. Dementsprechend ist die Verteilung dieser Kennzahl. Die scharfe Grenze zwischen den Intervall überdurchschnittlich (geringer Fremdkapitalanteil) und durchschnittlich liegt bei 9,0 % und die Grenze zwischen den Intervallen durchschnittlich und unterdurchschnittlich bei 21,7 %. Der Anteil der Unternehmen, die $\pm 5\%$ um die Grenze der Intervalle überdurchschnittlich und durchschnittlich liegen, beträgt 38 %.

Gleichzeitig weisen ein Drittel der Unternehmen einen Fremdkapitalanteil von 21,7 % und größer auf.

Dynamischer Verschuldungsgrad

ABB. 45: VERTEILUNG DER OUTPUTVARIABLEN "DYNAMISCHER VERSCHULDUNGSGRAD"



Quelle: Eigene Darstellung

TAB. 10: KENNWERTE: DYNAMISCHER VERSCHULDUNGSGRAD

Output-Variablen <i>Wj 96/97</i>	arithmet. Mittel	Standard- abweichung	Schiefe	Exzess
dynamischer Verschuldungsgrad in Jahre	2,18	10,72	21,69	506,46

Quelle: Eigene Berechnungen

Die Verteilung des *dynamischen Verschuldungsgrades* unterscheidet sich wiederum von den beiden anderen Kennzahlen. Das auffälligste, wie man anhand der Abb. 45 erkennen kann, sind die Extremwerte. Die Spannweite reicht bei den vorhandenen Daten von -19 Jahre bis zu 266 Jahre, wobei nur 1,3 % aller Unternehmen einen dynamischen Verschuldungsgrad größer als 10 Jahre aufweisen. Diesen Verteilungsverlauf belegt auch der Exzess, dessen Wert bei 506,46 liegt. Aus diesen

Gründen ist die Darstellung einer Normalverteilungskurve für den ausgewählten Wertausschnitt nicht möglich. Die Normalverteilungskurve hat in diesem Abschnitt einen fast geradlinigen Verlauf. Die Extremwerte kommen dadurch zustande, dass einige Unternehmen einen Cash flow aufweisen, der sich nur geringfügig von Null unterscheidet. Hierdurch wird der Nenner klein und die Kennzahl sehr groß.

Das arithmetische Mittel kann bei dem dynamischen Verschuldungsgrad nicht interpretiert werden, weil es sich bei diesem Funktionsverlauf um eine Asymptote handelt, die sich der Null annähert. Aus diesem Grund muss der Verteilungsverlauf des dynamischen Verschuldungsgrades für die Outputvariable einer Klassifizierung näher betrachtet werden.

Für den Abschnitt von - 1 Jahr bis 5 Jahre ist ersichtlich, dass 71 % aller Unternehmen einen dynamischen Verschuldungsgrad von 0 bis 1 Jahr aufweisen. Dies bedeutet, dass zwar eine hohe Varianz dieser Kennzahl vorliegt, diese aber aus wenigen und dafür extremen Werten resultiert. Der größte Teil der Unternehmen unterscheidet sich nur geringfügig. Weiter ist ein Bruch bei dem Wert 0 sichtbar. Der Wert 0 bedeutet, dass das Unternehmen 0 Jahre benötigt, bis das gesamte Fremdkapital zurückbezahlt worden ist. Das ist nur der Fall, wenn kein Fremdkapital geliehen worden ist. In diesem Fall handelt es sich um vollständig durch Eigenkapital finanzierte Unternehmen.

Ein negativer dynamischer Verschuldungsgrad ist nur gedanklich zu konstruieren. Er bedeutet, wieviel Einnahmeüberschuss gegenüber dem Fremdkapital anfällt. Der Wert beschreibt die Anzahl der Jahre, bis sich das Fremdkapital verdoppelt hat. Dementsprechend sind die Unternehmen mit einem negativen dynamischen Verschuldungsgrad bei einer Klasseneinteilung inhaltlich in die Klasse mit den unterdurchschnittlichen Werten einzuordnen, weil ein geringer positiver Cash flow für die finanzielle Situation des Unternehmens besser ist als ein negativer.

Dies bedeutet, dass bei einer relativen Klasseneinteilung der Beginn der Einteilung bei 0 anfängt und mit den negativen Werten endet. Folglich liegen die Intervallgrenzen bei 0,28 Jahre für überdurchschnittlich und durchschnittlich und bei 0,85 Jahre für die Grenze zwischen durchschnittlich und unterdurchschnittlich. In dem Intervall von $\pm 0,25$ Jahre um die Grenze von 0,28 Jahre liegen 50 % aller Unternehmen.

4.1.4.1.3 Erstellung von Fuzzy Mengen

Bei der Zuordnung der Unternehmen in die jeweilige Klasse eines FS kommt der Festlegung der Zugehörigkeitsfunktion eine größere Bedeutung zu. Diese Funktion kann aber wegen der bestehenden Unschärfe nicht exakt bestimmt werden, sondern sie lässt sich nur über einige charakteristische Punkte festlegen (vgl. Kapitel. 3.5.2). Da empirische Untersuchungen ergeben haben, dass sich s-förmige Zugehörigkeitsfunktionen besonders dazu eignen, menschliches Verhalten zu beschreiben, werden hier diese verwendet.

Für jede Output-Variable wird die Zuordnung der Unternehmen zu den Zugehörigkeitsgrad des jeweiligen linguistischen Fragmentes vorgenommen. Anschließend wird beispielhaft für die Gesamtkapitalrentabilität der Vorgang der Zuordnung beschrieben. Die Zuordnung für den dynamischen Verschuldungsgrad und dem Fremdkapital erfolgt in gleicher Weise.

Als Eckwerte für die Zugehörigkeitsfunktionen sind folgende Werte der Rangfolge gewählt worden (Abb. 46):

1. 900 (16,7 % der Unternehmen mit der niedrigsten Gesamtkapitalrentabilität)
2. 2.700 (50,0 %)
3. 4.500 (83,3 %)

Die Zugehörigkeitsfunktion für das Fragment "unterdurchschnittlich" lautet:

$$f(x; a, c) = \begin{cases} 1 & \text{für } x > 900 \\ 1 - \frac{1}{1 + e^{-a(x-c)}} & \text{für } 900 \leq x \leq 2.700 \\ 0 & \text{für } x < 2.700 \end{cases}$$

mit den Parameter $a = 0,0075$ und $c = 1.800$.

Die Zugehörigkeitsfunktion für das Fragment "durchschnittlich" wird mit folgender Funktion beschrieben:

$$f(x; a, c) = \begin{cases} 0 & \text{für } x < 900 \\ \frac{1}{1 + e^{-a(x-c_1)}} & \text{für } 900 \leq x < 2.700 \\ 1 - \frac{1}{1 + e^{-a(x-c_2)}} & \text{für } 2.700 \leq x \leq 4.500 \\ 0 & \text{für } x > 4.500 \end{cases}$$


mit den Parameter $a = 0,0075$ und $c_1 = 1.800$ und $c_2 = 3.600$

Die Zugehörigkeitsfunktion für das Fragment "überdurchschnittlich" lautet

$$f(x; a, c) = \begin{cases} 0 & \text{für } x < 2.700 \\ \frac{1}{1 + e^{-a(x-c)}} & \text{für } 2.700 \leq x \leq 4.500 \\ 1 & \text{für } x > 4.500 \end{cases}$$

mit den Parameter $a = 0,0075$ und $c = 3.600$.

ABB. 46: ZUGEHÖRIGKEITSFUNKTION FÜR DIE GESAMTKAPITALRENTABILITÄT



Quelle: Eigene Darstellung

Für die anderen beiden Output-Variablen sieht der Verlauf der Zugehörigkeiten zu den linguistischen Fragmenten identisch aus.

Als Output-Variablen für das FNN-Modell stehen jetzt nicht mehr die exakten Werte zur Verfügung, sondern das Netz lernt die Struktur der Daten anhand der Zugehörigkeitsgraden für die jeweiligen linguistischen Fragmente der entsprechenden Kennzahl. Für die Beurteilung des finanziellen Zustandes der Unternehmen werden die drei Kennzahlen über ein FS miteinander verknüpft, so dass eine Klassifizierung in die Klassen finanziell gefährdet oder nicht vorgenommen werden kann.

4.1.4.2 Input-Variablen

Da durch die Output-Variablen das Ereignis der "finanziellen Gefährdung" beschrieben wird, werden Input-Variablen herangezogen, die einen inhaltlichen Zusammenhang zu diesen Output-Variablen aufweisen und in den vorliegenden Datensätzen existieren bzw. aus den vorhandenen Datensätzen abgeleitet werden können.

Die aus dem Jahresabschluss zur Verfügung stehenden Informationen sind zu unvollständig, um diese Klassifizierung eindeutig vorzunehmen. Die Kennzahlen aus der Bilanz und der Gewinn- und Verlustrechnung liefern nur quantitative Informationen. Wesentliche qualitative Aspekte, die für die Klassifizierung notwendig wären, sind nicht enthalten. Im landwirtschaftlichen Bereich sind hier insbesondere die Qualität des Managements und der Mitarbeiter anzusprechen. Deshalb wird bei dieser Arbeit lediglich durch die Klassifizierung von Jahresabschlüssen auf den finanziellen Zustand des Unternehmens geschlossen.

Vorselektion

Vor dem Einsatz der Input-Daten muss eine Vorselektion der Daten unter der Berücksichtigung der allgemeinen Kriterien zur Kennzahlenbildung erfolgen (vgl. Kapitel 4.1.4.1 und 2.6.2).

Die Bedingung, dass sowohl im Zähler wie auch Nenner keine negative Werte vorhanden sein dürfen, ist bei der Eigenrentabilität nicht gegeben (vgl. Kapitel 4.1.4.1.1). In der zu untersuchenden Datenmenge werden die Unternehmen mit einem Eigenkapital von 0 und weniger vorweg ausselektiert. Anders als bei der Output-Variable sind die Kennzahlen für den Input bei der Analyse bekannt. Hierdurch ergibt sich die Möglichkeit, die Unternehmen mit einer Unterbilanz gesondert zu behandeln. Ein Unternehmen, bei dem eine Unterbilanz zum Analysezeitpunkt eindeutig feststeht, sollte nicht erst eine Prognose für die nächsten Jahre abwarten, sondern sofort eine detaillierte Ursachenforschung in bezug auf die Wirtschaftlichkeit vornehmen und seine Wirtschaftsweise danach ändern. Auswertungen haben gezeigt, dass Unternehmen, bei denen zum Analysezeitpunkt eine Unterbilanz vorlag, häufig auch drei Jahre später finanzielle Probleme aufwiesen. Nur ein Fünftel der Unternehmen hatte drei Jahre später durchschnittliche und bessere Gesamtkapitalrentabilitäten; 10 % wiesen danach durchschnittliche und bessere Eigenkapitalquoten auf. Diese Unternehmen hatten aber in den meisten Fällen zwischenzeitlich größere Privateinlagen getätigt. Somit kann die finanzielle Verbesserung dieser Unternehmen nur auf externe Einflüsse zurückgeführt werden. Da nach dieser Vorselektion alle Jahresabschlüsse mit einer Unterbilanz aussortiert worden sind, wird auch die Bedingung, dass Zähler und Nenner nicht gleichzeitig negativ werden dürfen, erfüllt.

Von den anderen Kennzahlen weist keine die Möglichkeit auf, dass sowohl Zähler wie Nenner negativ werden können.


Ein weiteres Problem sind die Kennzahlen, bei denen eine Null im Nenner existieren kann. In den vorliegenden Kennzahlen kann nur bei den "Zinsen" häufig der Wert Null im Nenner auftreten. Deshalb wird für die Zinsen der Kehrwert verwendet. Zusätzlich kann bei den folgenden Kennzahlen das Auftreten einer Null im Nenner nicht ausgeschlossen, aber auf wenige Ausnahmefälle beschränkt werden. Hierbei handelt es sich um folgende Kennzahlen: Gesamtkapitalrentabilität, dynamische Gesamtkapitalrentabilität, Umsatzrentabilität, Umlaufintensität, Liquidität 3.Grades, Deckungsgrad A, Ausschöpfung der Kapitaldienstgrenze, dynamischer Verschuldungsgrad, Unternehmensertrag zu Vermögen, Gewinn zu Unternehmensaufwand und Abschreibung zu Gewinn. Diese Ausnahmen werden über eine Plausibilitätskontrolle aussortiert.

Bei genauerer Analyse der Kennzahl dynamischer Verschuldungsgrad (vgl. Kapitel 4.1.4.1) stellt sich heraus, dass diese Kennzahl sich nicht ohne weiteres als Input-Variable eignet. Da aber ein hoher inhaltlicher Zusammenhang zwischen der Kennzahl heute im Vergleich zu vor drei Jahren besteht, ist es wünschenswert, wenn diese Kennzahl doch als Input-Variable verwendet werden könnte.

Um trotzdem nicht auf diese Kennzahl als Input-Variable zu verzichten, werden die Unternehmen anhand dieser Kennzahl sortiert und eine Rangfolge gebildet. Anhand dieser Rangfolge werden die Unternehmen in die Klassen überdurchschnittlich und unterdurchschnittlich sortiert. Die Zuordnung der linguistischen Fragmente über- und unterdurchschnittlich wird über der in Abb. 47 dargestellten Zugehörigkeitsfunktion vorgenommen.

Da für die Kennzahl Zinsaufwand zu Gewinn das gleiche Problem auftritt wie beim dynamischen Verschuldungsgrad, wird auch bei dieser Kennzahl die gleiche Umformung vorgenommen.

ABB. 47: ZUGEHÖRIGKEITSFUNKTION FÜR DEN DYNAMISCHEN VERSCHULDUNGSGRAD



Quelle: Eigene Darstellung

Ausgewählte Input-Variablen mit Begründung

Auf eine Auswahl der Input-Variablen mit Hilfe von statistischen Auswahlverfahren wird hier verzichtet, weil NN keine statistischen Voraussetzungen verlangen und deshalb die Variablen nach fachlichen Kriterien ausgewählt worden sind. Im weiteren Verlauf des Kapitels erfolgt eine nähere Erläuterung für die Auswahl dieser Variablen. Die Definition der Input-Variablen sind im Anhang beschrieben.

Die Klassifizierung der Unternehmen in den zwei Klassen "finanziell gefährdet" und "finanziell gesund" erfolgt anhand von insgesamt 26 Input-Kennzahlen. Aus folgenden inhaltlichen Bereichen sind Kennzahlen ausgewählt worden:

Ertrag und Rentabilität

TAB. 11: INPUT-KENNZAHLEN: ERTRAG/RENTABILITÄT

Input-Variable <i>Wj 91/92, 92/93, 93/94</i>	Ein- heit	Arithmetisches Mittel	Standard- abweichung	Schiefe	Exzess
<i>Ertrag/Rentabilität</i>					
Gewinn K 1	DM je Unternehmen	45.256	50.311	-4,18	33,51
Cash flow K 2	DM je Unternehmen	78.577	58.268	-2,24	25,63
Eigenkapitalveränderung K 3	DM je Unternehmen	4.599	18.094	-7,67	131,46
Eigenkapitalrentabilität K 4	Prozent	- 1,49	25,33	-10,41	143,35
Gesamtkapitalrentabilität K 5	Prozent	- 0,58	7,08	-6,89	88,39
dyn. Gesamtkapitalrent. K 6	Prozent	5,50	6,22	0,87	6,77
Umsatzrentabilität K 7	Prozent	-0,24	17,79	-6,59	81,28

Quelle: Eigene Berechnung

Eine langfristige finanzielle Stabilität der landwirtschaftlichen Unternehmen ist nur gewährleistet, wenn dauerhaft Gewinne erzielt werden. Dieses lässt sich mit Hilfe von Rentabilitäts- und Erfolgskennzahlen darstellen (LEFFSON, 1984, S.33). Die *Umsatzrentabilität* gilt als ein Indikator dafür, wie effizient ein Unternehmen arbeitet und welche Potentiale für die Bewältigung preisbedingter Krisensituationen zur Verfügung stehen (BODMER und HEIßENHUBER, 1993, S.280).

Mit Hilfe der *Gesamtkapitalrentabilität* (BARRY et al., 2000, S. 101) kann eine langfristige, erfolgreiche Produktion gemessen werden. Ein Unternehmen kann langfristig nur als finanziell gesund gelten, wenn es Gewinne erwirtschaftet. Eine der wichtigsten Ziele für jeden Unternehmer ist die Maximierung der *Eigenkapitalrentabilität* (BARRY et al., 2000, S. 101). Sie ist abhängig von der Kapitalstruktur des Unternehmens und unterscheidet sich hier von der Gesamtkapitalrentabilität.

Der *Gewinn* (BODMER und HEIßENHUBER, 1993, S. 280) liefert zusätzliche Informationen über den Unternehmenserfolg. Da es sich hierbei nicht um den kalkulatorischen Gewinn handelt, der in die übrigen Rentabilitätskennzahlen mit eingeht, wird der Erfolg in Abhängigkeit der eingebrachten, nicht entlohnten Produktionsfaktoren mit berücksichtigt. Weil der Gewinn als Beitrag für das Einkommen des Unternehmers wichtig ist, wird keine Verhältniszahl, sondern eine absolute Zahl verwendet.

Die Cash flow Kennzahl "*dynamische Gesamtkapitalrentabilität*" ist bisher in der Landwirtschaft nicht geläufig, aber da der *Cash flow* im Zusammenhang mit dem betrieblichen Wachstum und unter dem Aspekt der Entwicklungsfähigkeit des landwirtschaftlichen Unternehmens eine große Bedeutung hat (KÜTING und WEBER, 1994, S.124), wird er sowohl als absolute Zahl wie auch als Verhältniszahl zum Gesamtkapital mit aufgenommen.

Als Indikator der Entwicklungsfähigkeit wird jedoch nicht nur der Cash flow von Bedeutung sein, sondern auch die *Eigenkapitalveränderung* (BODMER und HEIßENHUBER, 1993, S. 284). Diese beiden Kennzahlen stehen allerdings in rechentechnischer Beziehung zueinander. Sie unterscheiden sich durch die Privatentnahmen, -einlagen und der Abschreibung. Der Cash flow weist die betrieblichen Finanzierungsmöglichkeiten und die Eigenkapitalveränderung unter Berücksichtigung der außerbetrieblichen Finanzlage, wie Lebensunterhalt und außerbetriebliches Vermögen, aus. Die Eigenkapitalveränderung informiert darüber, inwieweit die Gewinne und Privateinlagen ausgereicht haben, die Privatentnahmen abzudecken. Beim Cash flow werden die betrieblich zur Verfügung stehenden Finanzierungsmittel ohne Berücksichtigung der Privatentnahmen, aber einschließlich der Abschreibung, ausgewiesen.

Die beiden Kennzahlen Eigenkapitalveränderung und Cash flow geben im Zusammenhang mit dem Gewinn Auskunft auf welchen "*Entwicklungspfad*" sich das Unternehmen befindet. Deshalb liefern diese drei absoluten Kennzahlen einen zusätzlichen Erklärungsbeitrag für die Klassifizierung.

Anhand des Entwicklungspfades sind die anderen Kennzahlen unterschiedlich zu interpretieren. Folgende unterschiedliche Entwicklungspfade lassen sich kurz skizzieren:

- die Wachstumsbetriebe
- die unentschlossenen Betriebe
- die weichenden Betriebe

Betriebliches Wachstum und Finanzierungskraft

TAB. 12: INPUT-KENNZAHLEN: WACHSTUM UND FINANZIERUNGSKRAFT

Input-Variable <i>Wj 91/92, 92/93, 93/94</i>	Einheit	arithmetisches Mittel	Standardabweichung	Schiefe	Exzess
Wachstum					
Nettoinvestitionsquote K 8	Prozent	0,88	5,55	6,33	60,90
Durchschnittliche Nettoinvestitionen K 9	DM je Unternehmen n	8.803	122.706	3,20	19,57
Umsatzwachstum K 10	Prozent	4,65	20,50	1,65	6,27
Entwicklung FK K 11	DM je Unternehmen	5.261	80.204	2,11	12,87
Finanzierungskraft					
Ausschöpfung der Kapitaldienstgrenze K 12	Prozent	60,2	149,2	11,76	261,58
Zinsen K 13	Prozent	5,31	3,38	5,03	61,54
Dyn. Verschuldungsgrad K 14	Jahre	2,26	21,97	-17,28	347,87

Quelle: Eigene Berechnung

Das betriebliche Wachstum und die Finanzierungskraft wird von der Rentabilität und Ertragskraft des Unternehmens beeinflusst. Deshalb liefern die Kennzahlen für die Rentabilität auch Informationen über das betriebliche Wachstum und die Finanzierungskraft.

Je nach Rentabilität gibt es hier Unternehmen mit hohen Gewinnen aber negativer Eigenkapitalveränderung und Cash flow. In diesem Zusammenhang können auch die

weiteren absoluten Input-Variablen gesehen werden: Die *durchschnittliche Nettoinvestition* und die *Entwicklung des Fremdkapitals*.

Durch die enge Beziehung zwischen *Gesamtkapitalrentabilität*, *Eigenkapitalrentabilität*, *Zinssatz* (BARRY et al., 2000, S. 116), *Risiko* und dem *Unternehmenswachstum* werden hier alle diese Kennzahlen dem FNN-Modell zur Verfügung gestellt. Wie in Kapitel 4.1.4.1 beschrieben existiert eine gegensätzliche Beziehung zwischen Rentabilität und Risiko im Unternehmen.

Hieraus folgt, dass Unternehmen, die eine höhere Gesamtkapitalrentabilität als den zu zahlenden Zinssatz aufweisen, durch Produktionsausweitungen, die über Fremdkapital finanziert werden, eine höhere Eigenkapitalrentabilität erzielen. Höhere Eigenkapitalrentabilitäten führen wiederum zu einem stärkeren Wachstum des Eigenkapitals, das dann für weitere Wachstumsschritte zur Verfügung steht bzw. dazu führt, dass sich durch weiteres zusätzliches Eigenkapital die Stabilität des Unternehmens erhöht (BARRY et al., 2000, S. 168). Durch diesen Effekt ist das Unternehmen in der Lage beschleunigt zu wachsen, weil das Eigenkapital beschleunigt anwächst. Deshalb kann absolut mehr Fremdkapital aufgenommen werden, ohne dass sich die Zusammensetzung der Finanzstruktur verändert. Das mögliche Wachstum eines Unternehmens aus eigener Kraft ist davon abhängig, wie die Finanzstruktur und das Verhältnis Zinssatz zu Gesamtkapitalrentabilität ist.

Gleichzeitig tritt durch diesen Effekt aber ein zusätzliches Risiko auf. Da die Schwankungsbreite der Gesamtkapitalrentabilität im Zeitablauf hoch ist, besteht die Gefahr, dass dieser Wert unter dem Zinssatz liegt. Dies hat den gleichen oben erwähnten Effekt auf das Wachstum der Unternehmen, aber mit einem negativen Vorzeichen. Hierdurch wird eigenes betriebliches Wachstum bei einem hohen Fremdkapitalanteil überproportional gebremst. Zusätzlich verursacht die ungünstige Finanzierungsstruktur eine Einschränkung weiterer liquider Reserven. Durch diese Finanzierungsfälle können solche Unternehmen beschleunigt in finanzielle Schwierigkeiten geraten (SPREMANN, 1996, S. 301ff.).

Damit das FNN-Modell diese finanzielle Zusammenhänge mit berücksichtigen kann, sind die bisher erwähnten Input-Variablen notwendig. Zusätzlich ist das FNN-Modell in der Lage, die nicht linearen Zusammenhänge mit zu berücksichtigen.

Für das Wachstum der Unternehmen ist die Finanzierungskraft eine wichtige Einflussgröße. Diese wird durch die Kennzahlen *dynamischer Verschuldungsgrad* (KÜTING und WEBER, 1994, S.132), *Zinsdeckung* (BARRY et al., 2000, S.111) und *Ausschöpfung der Kapitaldienstgrenze* (BARRY et al., 2000, S. 112) abgebildet. Die Ausschöpfung der Kapitaldienstgrenze gibt die noch vorhandenen Reserven für weitere Tilgungs- und Zinszahlungen an. Die Zinsdeckung gibt an, wie viel des

Gewinns für die Zinszahlung aufgewendet werden muss und wie viel des Gewinns dann für die übrigen Produktionsfaktoren übrig bleiben.

Die *Nettoinvestitionsquote* wird vielfach als ein Maß für die Zukunftsvorsorge eines Unternehmens angesehen (vgl. GRÄFER, 1990, S.227 und vgl. KÜTING und WEBER, 1994, S.92). Die Kennzahl *Umsatzwachstum* gibt im Zusammenhang mit der Investitionsquote Auskunft darüber, ob die Investitionen für das Wachstum des Unternehmens verwendet worden sind oder ob hiermit eine kapitalintensivere Produktion vorgenommen wurde.

Vermögens- und Kapitalanalyse

TAB. 13: INPUT-KENNZAHLEN: VERMÖGENS- UND KAPITALANALYSE

Input-Variable <i>Wj 91/92, 92/93, 93/94</i>	Ein- heit	arithmetisches Mittel	Standard- abweichung	Schiefe	Exzess
<i>Vermögensanalyse</i>					
Umlaufintensität K 15	Prozent	5,66	4,96	3,59	22,84
Grund- u. Bodenanteil K 16	Prozent	69,81	26,87	-0,89	9,12
Anlageintensität K 17	Prozent	89,27	23,44	5,65	60,40
<i>Kapitalanalyse</i>					
Fremdkapitalanteil K 18	Prozent	19,1	18,43	2,27	9,70
<i>Vergleich Kapital - Vermögen</i>					
Liquidität 3. Grades K 19	Prozent	109,9	134,8	4,87	38,32
Deckungsgrad A K 20	Prozent	90,6	71,1	12,32	200,91

Quelle: Eigene Berechnungen

Die *Anlageintensität* (KÜTING und WEBER, 1994, S.88) gibt Aufschluss über die Flexibilität des Unternehmens. Je höher die Anlagenintensität ist desto höher ist die Festkostenbelastung und desto geringer kann sich das Unternehmen an geänderte Produktionsbedingungen anpassen, da jede Anlageveräußerung mit erheblichen Wertverlusten verbunden ist. Bei dieser Kennzahl ist das Bewertungswahlrecht zu beachten, da dieses zu erheblichen Differenzen führen kann. Von besonderer Bedeutung ist auch der *Grund- und Bodenanteil* am Gesamtvermögen. Dieser hat

einen bedeutenden Anteil an der finanziellen Stabilität und Rentabilität des Unternehmens.

Die Kennzahl *Umlaufintensität* (KÜTING und WEBER, 1994, S.89) ist mit einigen Unsicherheiten behaftet. Sie lässt nur begrenzt Rückschlüsse auf das tatsächliche Ausmaß der Kapitalbindung im Unternehmen zu. Ihre Aussagekraft wird stark unter anderem dadurch belastet, dass zahlreiche betriebsnotwendige Vermögensgegenstände nach den herrschenden Bilanzierungsvorschriften (vgl. Kapitel 2.3) keinen Eingang in die Bilanz finden.

Bei dem *Fremdkapitalanteil* (BODEMER und HEIßENHUBER, 1993, S.263) taucht auch das Problem der Bodenbewertung auf. Die in der Bilanz ausgewiesenen Werte weichen teilweise erheblich von den tatsächlichen ab. Aufgrund der Output-Variable Fremdkapitalanteil ist sie aber eine wichtige Input-Kennzahl. Sie ist außerdem eine wichtige Kennzahl im Zusammenhang der Rentabilitätskennzahlen, für Wachstumsschritte und für die Einschätzung der Stabilität des finanziellen Lage des Unternehmens.

Die Kennzahl *Liquidität 3. Grades* (BODEMER und HEIßENHUBER, 1993, S.269) beinhaltet nur eine Aussage zur Zeitpunktliquidität (allerdings im 3jährigen Durchschnitt) und hat deshalb nur eine eingeschränkte Aussagefähigkeit. In Verbindung mit der Kennzahl *Deckungsgrad A* (KÜTING und WEBER, 1994, S.115) bilden diese beiden Input-Variablen die Grundsätze der Fristenkongruenz ab. Hiermit erfolgt die Beurteilung der Solidität der Finanzierung des Unternehmens.

Finanzielle Effizienz

TAB. 14: INPUT-KENNZAHLEN: FINANZIELLE EFFIZIENZ

Input-Variable <i>Wj 91/92, 92/93, 93/94</i>	Ein- heit	arithmetisches Mittel	Standard- abweichung	Schiefe	Exzess
Finanzielle Effizienz					
Unternehmensertrag zu Vermögen K 21	Prozent	20	14	1,75	2,99
Gewinn zu Unternehmensaufwand K 22	Prozent	23	96	10,34	219,69
Abschreibung zu Gewinn K 23	Prozent	71	65	1,03	61,41
Zinsdeckung K 24	Prozent	18	179	21,53	481,43
Allgemein					
LF K 25	ha	42,5	20,7	1,61	5,43
Abnutzungsgrad der Maschinen K 26	Prozent	34	11	0,01	-0,01

Quelle: Eigene Berechnungen

Des weiteren folgen die Kennzahlen der finanziellen Effizienz. Die Kennzahl *Unternehmensertrag zu Vermögen* gibt an, wie effizient das Kapital eingesetzt worden ist (BARRY et al., 2000, S. 116). Die Kennzahl *Gewinn zu Unternehmensaufwand* (BARRY et al., 2000, S. 116) deutet darauf hin, welche Unternehmen Defizite bei den Aufwendungen aufweisen. Aus der Kennzahl *Abschreibung zum Gewinn* (BARRY et al., 2000, S. 116) kann geschlossen werden, wie hoch proportional die Fixkosten der Abschreibungen zu den Gewinnen sind und wie effizient zum eingesetzten Vermögen gewirtschaftet wird bzw. wie neu das vorhandene Vermögen von Gebäuden und Maschinen ist. Hohe Abschreibungen zu niedrigen Gewinnen deuten daraufhin, dass das Unternehmen vor kürzerer Zeit durch Investitionen gewachsen ist.

Der *Abnutzungsgrad der Maschinen* dient als Indikator für die Altersstruktur der Maschinen. Hier lassen sich Anhaltspunkte für erforderliche Ersatzinvestitionen in der

Zukunft ableiten und den dadurch ausgelösten Kapitalbedarf gewinnen. Diese Kennzahl darf nicht überinterpretiert werden, weil die Nutzungsdauer der Maschinen und die Abschreibungszeiträume unterschiedlich sein können.

Die absolute Kennzahl LF (Landwirtschaftliche Fläche) soll dem FNN dazu dienen Zusammenhänge besser zu strukturieren.

4.2 Klassifizierung landwirtschaftlicher Jahresabschlüsse

Anhand der ausgewählten Input- und Output-Variablen wird das FNN-Modell entwickelt. Die technische Umsetzung des FNN-Modells erfolgt mit Hilfe von entsprechender Software.

4.2.1 Software für das FNN

Das Angebot der Software für die Modellbildung von NN ist groß und ändert sich ständig (STOLZKE, 1999). Es haben sich allerdings nur wenige Programme fest etabliert. Die Software des SNNS (Stuttgarter Neuronale Netze Simulator), ein effizienter Simulator des Instituts für Parallele und Verteilte Höchstleistungsrechner (IPVR) der Universität Stuttgart sowie das Anwendungsmodul von SPSS "Neural Connections" dienen bei dieser Untersuchung als Software.

SNNS ist ein effizienter Simulator künstlicher Neuronaler Netze auf Unix Workstations. Es ist ein Werkzeug zur Generierung, zum Training, zum Testen und zur Visualisierung der NN. Der Simulator besteht aus drei größeren Komponenten: einen Simulatorkern, der auf der internen Repräsentation der NN arbeitet, einer graphischen Benutzeroberfläche basierend auf X-Windows, und einem Compiler zur Generierung der internen Repräsentation großer NN aus einer höheren Netzwerk-Beschreibungssprache.

SNNS hält eine Vielzahl von Netztypen bereit, die zur Klassifizierung verwendet werden können. Auch die vielfältigen Möglichkeiten von Schnittstellen zu anderer Software, beispielsweise zu GA (Genetischen Algorithmen), enthalten interessante Zusatzaspekte. Außerdem enthält es weitere Werkzeuge zur Analyse der Netze, wie das Hinton-Diagramm-Fenster zur Analyse der Gewichte eines Netzes als Matrix von Quadraten verschiedener Größen und Farben.

Das Anwendungsmodul "Neural Connection" von SPSS ist zwar nicht so vielseitig wie das SNNS, aber für die hier benötigten Anwendungen ist es ausreichend. Es besitzt dafür eine anwenderfreundliche Benutzerumgebung (STOLZKE, 1999). Für den Einsatz des MLP bietet diese Software eine gute Voraussetzung für einen erfolgreichen Einsatz. Im Hinblick auf den praktischen Einsatz bietet SPSS Vorteile durch seinen hohen Bekanntheitsgrad und einfache Bedienung im Vergleich zu den anderen NN-Programmen.

Als Software für die Anwendung der FS eignet sich besonders gut das Produkt der Inform Software Corporation "fuzzyTech[®] 5.4", die eine gute Auswahl an Zugehörigkeitsfunktionen, Inferenz- und Defuzzifizierungsmethoden bietet. Aus diesem Grund kommt sie hier zum Einsatz.

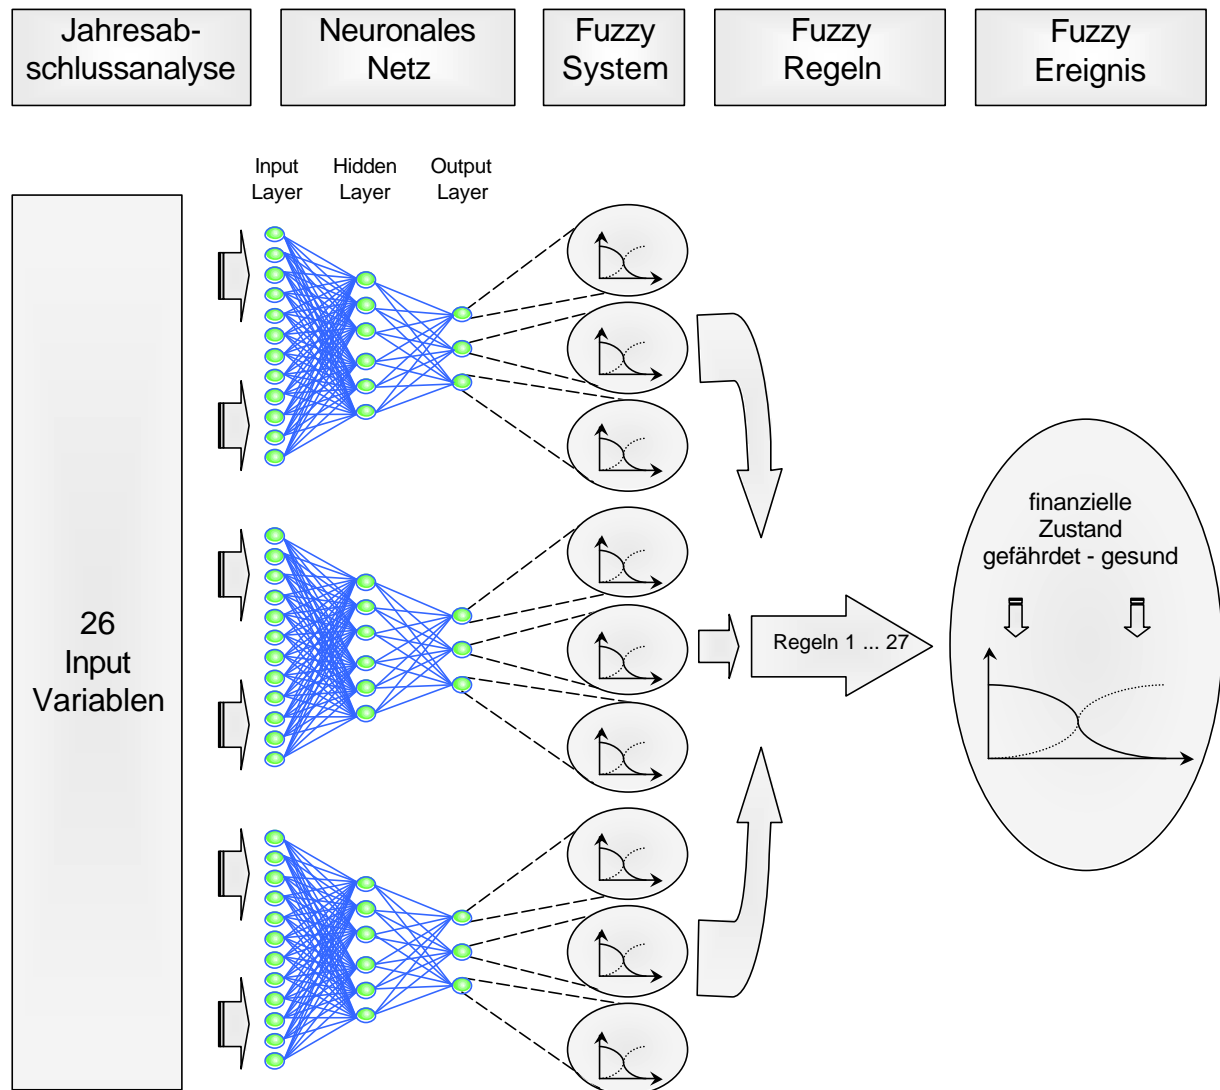
4.2.2 Aufbau des Modells

Die Festlegung des Ereignisses "*finanzielle Gefährdung*", nach dem das NN die Klassifizierung vornehmen soll, ist nicht empirisch beobachtbar. Die Beschreibung erfolgt anhand der drei Output Kennzahlen Gesamtkapitalrentabilität, dynamischer Verschuldungsgrad und Fremdkapitalanteil. Die Zusammenfassung dieser drei Kennzahlen zu einem Ereignis erfolgt über ein FS.

Die Gesamtklassifizierung wird unterteilt in ein NN und ein FS. Das NN klassifiziert nicht das Ereignis, sondern die Kennzahlen. Für jede Output-Kennzahl wird ein NN erstellt. Die Jahresabschlüsse werden nach den einzelnen Output-Variablen klassifiziert. Die klassifizierten Outputvariablen werden dann durch ein FS zu dem Ereignis der finanziellen Gefährdung zusammengeführt.

Um die Gesamtklassifizierung zu verbessern, reicht die Klassifizierung der Output-Variablen in nur zwei Gruppen nicht aus. Die Beschreibung des Ereignisses der finanziellen Gefährdung durch nur zwei linguistische Variablen - überdurchschnittlich und unterdurchschnittlich - beinhaltet zu wenige Informationen für die Bildung der Fuzzy Regeln. Aus diesem Grund klassifiziert jedes NN die Zugehörigkeitsfunktionen von drei linguistischen Variablen.

Weil das NN nur binär klassifizieren kann, können die drei verschiedenen Ausprägungen einer Kennzahl nur durch drei Outputs klassifiziert werden. Die drei Outputs der jeweiligen Kennzahl lauten überdurchschnittlich, durchschnittlich und unterdurchschnittlich.

ABB. 48: AUFBAU DES FNN MODELLS ALS MLP

Quelle: Eigene Darstellung

4.2.3 Entwicklung und Optimierung eines FNN-Modells

4.2.3.1 Auswahl des NN

Aufgrund bisheriger Erfahrungen von Klassifizierungsergebnissen der unterschiedlichen Netzwerkstrukturen (KERLING und PODDIG, 1994, S.460ff.) wird in dieser Arbeit auf das am häufigsten eingesetzte Netzwerkmodell MLP (Multilayer-Perceptron) zurückgegriffen. Der hier verwendete Backpropagation-Algorithmus ist in Kapitel 3.4.6.3 näher erläutert worden. Es wird für jede Output-Kennzahl ein dreischichtiges MLP entwickelt (vgl. Abb. 48). Auf das LVQ (Learning Vector Quantization) wird trotz des interessanten Klassifizierungsansatzes aufgrund bisheriger Ergebnisse (KERLING und PODDIG, 1994, S. 439) verzichtet.

Auswahl der Netztopologie

Beim Training des Netzes geht es darum, die beste Netztopologie für die jeweilige Problemstellung zu finden. Aus den bisherigen Erfahrungen ist es zur Lösung des XOR-Problems notwendig, mindestens ein dreilagiges Netzwerk zu verwenden, um die Nichtlinearität nutzen zu können (ZELL, 1994, S.74 ff.). Dreilagige Netzwerke sind in der Lage, beliebige Funktionen zu approximieren. Sie reichen für die meisten ökonomischen Problemstellungen aus. Somit ist die Basisstruktur des Netzwerks festgelegt. Es besteht aus einem Input-, Hidden- und Output-Layer.

Das Klassifizierungsergebnis wird vorwiegend von der Auswahl der Input-Kennzahlen abhängen. Fehlende oder falsche Input-Daten haben einen erheblich größeren Einfluss auf das Klassifizierungsergebnis als die Parametereinstellung, wie viele Versuchsdurchläufe gezeigt haben. Trotzdem ist die Parametereinstellung der NN für die Feinabstimmung wichtig.

Parametereinstellung

Der Einsatz von NN basiert nicht auf festen mathematischen Vorgaben, sondern ist ein Prozess des "trial and error", da es an Algorithmen für die notwendigen Parametereinstellungen mangelt. Das Probieren führt dazu, dass auch viele Wege beschritten werden, die sich letztlich als Sackgassen erweisen. Dementsprechend müssen die Parametereinstellungen vom Entwickler variiert werden, bis das NN gute Klassifizierungsergebnisse liefert. Hieraus resultiert die Vorgehensweise für das Modell.

Die Eigenschaften der NN können grundsätzlich über mehrere Parametereinstellungen beeinflusst werden. Sie müssen deshalb optimiert werden. Da die einzelnen Parameter teilweise kontinuierliche Wertebereiche aufweisen, ist es in einem begrenzten Zeitraum nicht möglich, alle denkbaren Parameterkonstellationen zu überprüfen. Die Parameter müssen mit heuristischen Verfahren einer Optimallösung angenähert werden, weil keine analytischen Verfahren zur Ermittlung einer optimalen Parametereinstellung existieren.

Die Einstellung der Parameter nur durch Intuition des Netzarchitekten vorzunehmen, wie Kratzer vorschlägt (KRATZER, 1993, S. 167), erscheint wenig sinnvoll. Die Parametereinstellung mit Hilfe eines Gradientenabstiegsverfahrens zu optimieren ist ein sehr komplexes Problem aufgrund der Bildung partieller Ableitungen nach den netzspezifischen Parametern (KRAUSE, 1993, S.134). Wegen der einfacheren Handhabung wird in dieser Arbeit das Koordinaten-Verfahren verwendet. Mit diesem Verfahren können mehrdimensionale Optimierungsprobleme gelöst werden (BERG und KUHLMANN, 1993, S.294).

Koordinaten-Verfahren


Das Koordinaten-Verfahren kann die Einstellung eines NN folgendermaßen unterstützen (HORST, 1979, S.139):

1. Die Suche beginnt mit einem NN, dessen Parameter bereits solche Voreinstellungen haben, dass das Netz nach dem Lernen in der Lage ist, Datensätze der Teststichprobe angemessen zu klassifizieren. Ein Netz, das hierzu nicht in der Lage ist, würde vermutlich auch bei der Variation eines einzelnen Parameters noch nicht klassifizieren können. In diesem Fall beginnt das Koordinaten-Verfahren erst gar nicht mit der Suche.
2. Die Parameter werden der Reihe nach einzeln in beide möglichen Richtungen variiert. Danach erfolgt eine Überprüfung, ob sich das Klassifizierungsergebnis verbessert hat. Die Spannbreite der Variation der Parameter wird individuell festgelegt. Wenn keine Veränderung an einem Parameter Verbesserungen der Klassifizierungsgenauigkeit bringt, endet die Suche.
3. Werden die Klassifizierungsergebnisse durch eine geringfügige Variation eines Parameters verbessert, so wird dieser Parameter so lange verändert, bis sich die Ergebnisse nicht mehr verbessern. Die Variation eines Parameters führt nur bei unimodalen Funktionen zur optimalen Einstellung dieses Parameters. Durch eine Intervallschachtelung lässt sich eventuell das Ergebnis noch weiter verbessern. Die Intervallschachtelung kann aber nicht ad infinitum fortgesetzt werden. Die Variation eines Parameters wird deshalb abgebrochen, wenn der Einfluss der Variation auf das Ergebnis verhältnismäßig gering ist. Weil der Einfluss der verschiedenen Parameter auf das Ergebnis sehr unterschiedlich sein kann, muss für jeden Parameter getrennt entschieden werden, wann die Variation dieses Parameters beendet wird. Wenn ein Parameter hinreichend weit verbessert worden ist, wird die Suche nach der nächsten Parametereinstellung erfolgen.

Die Messung der Güte der besten Parametereinstellung erfolgt in dieser Untersuchung nicht anhand der Messung der korrekten Klassifizierung. Aufgrund der unscharfen Klassifizierungsgrenzen, ist das Kriterium der korrekten Klassifizierung nicht brauchbar. Deshalb wird zur Messung der besten Klassifizierungsgüte die MSE (mittlere quadratische Abweichung) der tatsächlichen Output-Werten zu den klassifizierten Output-Werten ermittelt.

4.2.3.2 Architektur des verwendeten Neuronalen Netzes

Der grundsätzliche Aufbau eines MLP ist in Kapitel 3.4.6.2 dieser Arbeit beschrieben worden. Das verwendete Netz hat folgenden Aufbau:

ABB. 49: AUFBAU EINES MLP (SCHEMATISCH)

Quelle: Eigene Darstellung

Das dargestellte Netz ist ein dreischichtiges Perzeptron. Der Input-Layer besteht aus 26 Input-Variablen - für jede Kennzahl ein Neuron. Der Output-Layer beinhaltet drei Neuronen. Pro Output-Kennzahl wird zwar ein separates NN angefertigt, da aber die Klassifizierung der jeweiligen Output-Kennzahl in überdurchschnittlich, durchschnittlich und unterdurchschnittlich erfolgt, muss der Output-Layer hierfür drei Neuronen bereitstellen.

In dem verwendeten Backpropagation-Netz ist jedes Neuron des Input-Layers mit jedem Neuron des Hidden-Layers verbunden. Ebenso ist jedes Neuron des Hidden-Layers mit jedem Neuron des Output-Layers verbunden. Die Neuronen des Input-Layers enthalten einen Eingabewert und liefern diesen weiter zu den Neuronen des Hidden-Layers. Jedes Neuron des Output-Layers erhält den Eingabewert von allen Hidden-Neuronen und liefert den Ausgabewert.

Zuerst wird das NN anhand der Lernmenge (vgl. Kapitel 4.1) trainiert. Als Lernregel wird die Backpropagation-Lernregel (vgl. Kapitel 3.4.6.3) verwendet. Das Lernen erfolgt durch die Anpassung der Gewichte. Nach jedem Lernzyklus wird die Qualität des Netzes anhand einer Validierungsstichprobe (vgl. Kapitel 3.4.9) überprüft. Hierbei werden keine Gewichtswerte mehr angepasst.

Um das Netz mit der höchsten Klassifizierungsfähigkeit zu erhalten, müssen die Parameter des Netzes getestet werden. Dabei werden folgende Parameter unterschieden:

Netzspezifische Parameter:

- Zahl der Iterationen,
- Lernrate,
- Momentumsfaktor,
- Aktivierungsfunktion,
- Unterschreiten eines Fehlerniveaus.

Anwendungsspezifische Parameter:

- Anzahl der Lerndaten,
- Anzahl der Validierungsdaten,
- Anzahl der Input-Variablen.

Eine Schwierigkeit des *Koordinaten-Verfahrens* liegt darin, dass es die Unabhängigkeit der Parameter voraussetzt. Die Einstellung der Parameter, wie beispielsweise die Lernrate und die Anzahl der Iterationen, sind allerdings nicht unabhängig voneinander. Bei einer verminderten Lernrate steigt die Anzahl der Iterationen und umgekehrt. Durch zusätzliche Überlegungen muss man daher interdependente Beziehungen der Parameter einbeziehen.

Beim Lernen werden die Eingangssignale von dem Input-Layer in den Hidden-Layer mit den Verbindungsgewichten (vgl. Abb. 49) gewichtet, summiert und über die Ausgabefunktion an die Output-Neuronen gesendet, wo der gleiche Prozess abläuft. Das Ausgangssignal des Output-Neurons liefert den Ausgabewert.

4.2.3.3 Parametereinstellung

Als erstes wird eine Starteinstellung der Parameter erforderlich, um das Koordinaten-Verfahren zu verwenden. Für die Starteinstellung werden die Parameter wie folgt festgelegt (SCHÖNEBURG, 1990, S. 96).

- Lernrate beträgt 0,9
- Momentumsfaktor 0,1
- Lernalgorithmus: Backpropagation-Lernverfahren
- Aktivierungsfunktion des Hidden-Layers: sigmoide Funktion
- Netzarchitektur: 26 - 26 - 3 (Input-, Hidden-, Output-Layer)
- Unterschreiten des Fehlerniveaus: 0,001 (Lernen)

Um die bestmögliche Einstellung der voneinander abhängigen Variablen *Lernrate*, *Momentumsfaktor*, *Lernmenge* und *Anzahl der Iterationen* vorzunehmen, wird als erstes durch hintereinander geschaltete Netzwerkdurchläufe das Netz mit dem geringsten MSE ermittelt.

Eine ausreichende Anzahl an Iterationen ist notwendig für ausreichendes Lernen des NN. Allerdings ist das Problem des Überlernens zu beachten. Es gibt keine zuverlässige Möglichkeit, die Anzahl der Iterationsschritte festzulegen. Wenn das Lernen nach verhältnismäßig wenig Epochen abgebrochen werden muss, so hat das lernende System kaum eine Chance, komplizierte Nichtlinearitäten in den Zeitreihen zu finden.

Die Wahl des Lernfaktors ist entscheidend für das Verhalten des Backpropagation-Algorithmus. Zu kleine Werte bringen einen großen, oft praktisch nicht akzeptierbaren Zeitaufwand für das Lernen mit sich (vgl. Kapitel 3.4.6.3). Die Wahl des Lernfaktors hängt in erster Linie von der Anzahl der Iterationen und der Lernmenge ab. In der Literatur gibt es nur wenig Hinweise für die optimale Wahl der Lernrate. Oft wird empfohlen, mit einem relativ großen Lernrate zu beginnen und diese dann langsam zu vermindern.

Die Lernrate muss im Zusammenhang mit der Anzahl der Datensätze der Lernmenge gesehen werden. Wenn große Lernraten und große Mengen von Datensätzen vorliegen, wie bei der vorliegenden Lernmenge, dann ist das Gewicht der zuletzt gelernten Datensätze größer als das Gewicht der Datensätze, die zu Beginn gelernt wurden. Die Klassifizierungsleistung des Netzwerkes wird damit auch von der Reihenfolge der Datensätze bestimmt. Von der Tendenz her soll daher die Lernrate

um so kleiner gewählt werden, je mehr Datensätze in der Lernphase zur Verfügung stehen (KRAUSE, 1993, S. 158).

Aus diesen Gründen wird die Lernrate erst mit 0,9 gewählt und dann schrittweise auf 0,4 reduziert. Bei der Lernrate von 0,9 wird zuerst mit einer reduzierten Lernmenge von 100 Datensätzen, die nach dem Zufallsprinzip ausgewählt worden sind, trainiert. Danach erfolgt die Verringerung der Lernrate auf 0,7; 0,5 und 0,4. Im Gegenzug wird der Momentumsfaktor von 0,1 über 0,3 und 0,5 auf 0,6 hoch gesetzt. Die Lernmenge erhöht sich von 100 über 500, 1000 auf 3.778 Datensätze.

Da es sich bei großen Lernraten um eine schnelle und grobe Suche handelt, werden die Iterationsschritte auf 100 begrenzt. Die Anzahl der Iterationsschritte wird dann schrittweise von 100 über 1.000 und 5.000 auf 10.000 erhöht.

TAB. 15: PARAMETEREINSTELLUNGEN FÜR DAS NN

	1. Durchlauf	2. Durchlauf	3. Durchlauf	4. Durchlauf
Lernrate	0,9	0,7	0,5	0,4
Momentumsfaktor	0,1	0,3	0,5	0,6
Lernmenge	100	500	1.000	3.778
Anzahl der Iterationen	100	1.000	5.000	10.000

Quelle: Eigene Berechnungen

Diese vier Durchläufe werden hintereinander geschaltet. Das geschieht folgendermaßen: Der 2. Durchlauf setzt bei den ermittelten Gewichten an, bei denen der 1. Durchlauf den niedrigsten MSE ausgewiesen hat. Der 3. Durchlauf wiederum verwendet zu Anfang die Gewichte, bei denen der MSE im 2. Durchlauf am niedrigsten war usw.. Folgende MSE wurden bei der vorgegebenen Netzstruktur für die drei Output-Kennzahlen nach vollständiger Durchführung dieses Verfahren ermittelt:

TAB. 16: MSE FÜR DIE ERSTEN PARAMETEREINSTELLUNGEN

	Gesamtkapitalrentabilität	dyn. Verschuldungsgrad	Fremdkapitalanteil
MSE	0,631	0,487	0,531

Quelle: Eigene Berechnungen

Die beschriebene Vorgehensweise wird für jedes weitere Lernen des NN angewandt. Die Auswahl anderer Aktivierungsfunktionen als der sigmoiden Funktion führte bei allen drei Kennzahlen zu einem größeren Fehlerwert. Deshalb wird diese auch für die weiteren Parametereinstellungen beibehalten.

4.2.3.4 Optimierung des Netzwerkes

Den größten Einfluss auf die Verbesserung der Klassifizierungsleistung hat die Verwendung geeigneter Input-Daten. Da ein NN ohne theoretischen Hintergrund auskommt, also die Beziehungen zwischen Input- und Output-Daten nicht bekannt sein müssen, ist es für einen niedrigen MSE wichtig, dass die geeigneten Input-Daten verwendet werden. Es sollen keine Informationsverluste durch Input-Überlagerungen und verrauschte Daten entstehen.

Für die Optimierung des NN muss die Zahl der freien Parameter verkleinert werden, um das Gedächtnis des Netzwerkes zu begrenzen. So kann das Netz erst zu einer adäquaten Approximation der Nichtlinearität gelangen. Erst dann liegt eine geeignete strukturelle Verbindung von Input und Output vor. Um das Netzwerk zu optimieren, existieren verschiedene Methoden: Zu diesen zählen *Weight decay* (ZELL, 1994, S. 117) und *Optimal Brain Damage* (ZIMMERMANN, 1994, S. 67). Die Anwendung der Methoden *Weight decay* und *Optimal Brain Damage* führen zu keiner signifikanten Verbesserung des Fehlers MSE. Auch Ergebnisse von ZIMMERMANN (1994) zeigen, dass diese Verfahren bei einer hohen Komplexität des NN und bei einem hohen Anteil an Rauschen in den Daten (Jahresabschlüsse) nicht die geeignetsten Instrumente zur Optimierung der Netzwerktopologie darstellen.

Die gewählte Vorgehensweise für die Optimierung des Netzwerkes orientiert sich daher an den Koordinaten-Verfahren und läuft folgendermaßen ab: Gestartet wird jeweils mit allen 26 Input-Variablen und mit 26 Hidden-Neuronen. Zuerst wird die Anzahl der Hidden-Neurone optimiert. Bei der Testserie wird nach und nach jeweils ein Neuron aus dem Hidden-Layer entfernt, bis dieser nur noch drei Neuronen enthält. Die obere Grenze der Hidden-Neurone resultiert aus der Anzahl der Input-Neuronen und die untere Grenze aus der Anzahl der Output-Neuronen (KRATZER, 1993, S. 149). Zu groß dimensionierte Hidden-Layers führen dazu, dass eine Tendenz zur Reproduktion, also zum Auswendiglernen vorliegt. Wird die Anzahl der Neuronen im Hidden-Layer zu stark reduziert, ist das Netz nicht immer in der Lage, die entsprechende Separationsebene hinsichtlich jeder Ausgabezelle durch die Hidden-Neurone zu formen.

Danach erfolgt die Reduzierung der Input-Kennzahlen. Anhand der Gewichte können die Input-Variablen ausgewählt werden, die die kleinsten Gewichte aufweisen. Die Anzahl der Neurone des Hidden-Layers entspricht bei diesen Durchläufen jeweils der Anzahl der Input-Variablen. Zuerst werden die fünf Input-Variablen mit den geringsten Gewichten nach und nach aussortiert. Die Input-Variablen, die bei ihrer Nichtberücksichtigung dazu führen, dass der MSE gleich bleibt oder sich verkleinert, werden in den nächsten Trainingsdurchläufen nicht mehr berücksichtigt, weil diese offensichtlich das NN stören. Wenn sich der MSE vergrößert, wird diese Input-Variable wieder aufgenommen.

Dieses Vorgehen unterstellt, dass die Aussonderung eines Inputs die Verbindungsgewichte und die Bedeutung aller anderen Merkmale unbeeinflusst lässt. Diese Annahme ist sicher nicht korrekt, da gerade die Kombination und nicht die isolierten Merkmale selbst von entscheidender Bedeutung sind. Anhand des Koordinaten-Verfahrens wird versucht, dieses Problem zu lösen. So werden auch gleichzeitig zwei, drei, vier und fünf Input-Kennzahlen weggelassen, und das jeweilige MSE ermittelt. Es werden nachher die Input-Kennzahlen aussortiert, bei denen das NN einen höheren MSE-Wert aufweist.

Nachdem so die ersten Input-Variablen aussortiert worden sind, werden die nächsten fünf Input-Kennzahlen weggelassen. Danach folgt die Vorgehensweise wie eben beschrieben. Dieses Verfahren wird so lange durchgeführt, bis keine kleineren MSE-Werte ermittelt werden können.

Folgende Input-Variablen (vgl. Tab. 11, 12, 13, 14 und 17) sind für die drei trainierten NN aussortiert worden.

TAB. 17: AUSSORTIERTE INPUT-VARIABLEN IM FNN-MODELL

Input-Variablen für die drei NN		
<i>Gesamtkapitalrentabilität</i>	<i>Dynamischer Verschuldungsgrad</i>	<i>Fremdkapitalanteil</i>
Entwicklung des Fremdkapitals	Eigenkapitalveränderung	Abnutzungsgrad der Maschinen
Anlageintensität	Gewinn	Anlageintensität
Cash flow	Liquidität 3. Grades	Cash flow
Deckungsgrad A	Umsatzwachstum	Durchschnittliche Nettoinvestitionen
Fremdkapitalanteil		Grund- und Bodenanteil
Grund- und Bodenanteil		Liquidität 3. Grades
Liquidität 3. Grades		Umsatzrentabilität
Nettoinvestitionsquote		
Umsatzwachstum		

Quelle: Eigene Berechnungen

Damit haben sich die folgenden Anzahlen an Input-Variablen für die jeweiligen NN als geeignet erwiesen:

- $NN_{\text{Gesamtkapitalrentabilität}}$ 17 Neuronen,
- $NN_{\text{Fremdkapitalanteil}}$ 22 Neuronen,
- $NN_{\text{dynamischer Verschuldungsgrad}}$ 19 Neuronen.

Eine Erforschung der Ursachen, weshalb gerade diese Kennzahlen als Input-Variablen dazu führen, dass sich der Fehler erhöht, ist inhaltlich nur unbefriedigend möglich. Es können lediglich Vermutungen darüber angestellt werden, wieso diese Kennzahlen zu höheren Fehlern führen. Erste Ansätze dazu, wie eine Interpretation erfolgen könnte, sind bei KERLING und POODIG (1994, S. 482ff.) beschrieben.

Es kann aber festgestellt werden, dass die verbliebenen Input-Variablen ausreichen, um das NN zu trainieren. Die restlichen Input-Kennzahlen liefern keine zusätzlichen Informationen bzw. führen dazu, dass die Wechselwirkungen sich so stark überlagern, dass das NN die Struktur der Daten nicht mehr erkennen kann.

Danach werden für die jeweiligen Input-Variablen noch einmal die Hidden-Neuronen optimiert. Dieses Verfahren läuft in der gleichen Weise ab wie vorher beschrieben. Die MSE-Werte für die jeweilige Anzahl an Hidden-Neuronen sind in der Tab. 18 zusammengestellt worden. Bei allen drei NN ist der Fehler am niedrigsten, wenn die Hidden-Layer aus sechs Hidden-Neuronen bestehen.

Tab.18: MSE-Werte bei unterschiedlicher Neuronenanzahl im Hidden-Layer

Anzahl der Neuronen im Hidden-Layer	MSE-Werte für die drei trainierten NN		
	Gesamtkapitalrentabilität	Fremdkapital-anteil	Dynamischer Verschuldungsgrad
3	0,588	0,453	0,516
4	0,614	0,454	0,522
5	0,595	0,448	0,519
6	0,567	0,422	0,506
7	0,591	0,455	0,523
8	0,595	0,451	0,536
9	0,625	0,478	0,519
10	0,601	0,498	0,517
11	0,603	0,471	0,539
12	0,591	0,465	0,517
13	0,632	0,501	0,567
14	0,590	0,485	0,522
15		0,476	0,511
16		0,456	
17		0,459	
18		0,496	
19		0,454	

Quelle: Eigene Berechnungen

4.2.4 Bildung des Ereignisses der finanziellen Gefährdung aus mehreren Kennzahlen

Die Klassifizierung des NN führte bisher dazu, dass die Jahresabschlüsse nach den einzelnen Kennzahlen eingeteilt worden sind. Dieses beinhaltet noch keine Klassifizierung nach dem finanziellen Zustand.

Bisherige Ansätze zur Beschreibung des finanziellen Zustandes eines Unternehmens liegen beispielsweise bei BAETGE (1994) vor. Er versucht, durch eine differenzierte Einteilung von Unternehmen ein Rating-System aufzubauen. Hierfür wird ein N(etz)-Wert definiert. Dieser drückt aus, wieviel Potential ein Unternehmen zur Bekämpfung möglicher künftiger Widrigkeiten hat und kann als eine Art Grad der finanziellen Gefährdung interpretiert werden. Bei einem hohen N-Wert liegt eine hohe innere finanzielle Stabilität vor. Der N-Wert beschreibt die Fähigkeit zur innerbetrieblichen

Überwindung von ungünstigen Entwicklungen der Außenwelt sowie die Wettbewerbsfähigkeit gegenüber der Konkurrenz. Bei BAETGE ist der N-Wert ein aus dem vergangenheitsorientierten Jahresabschluss gewonnener Indikator für künftige Entwicklungen. Er zeigt auf, welches Potential zur Bekämpfung finanzieller Schwierigkeiten im Unternehmen gespeichert ist.

Dieser Indikator ist nicht eingeschränkt auf die ja-oder-nein Aussage: finanziell gefährdet oder finanziell gesund, sondern gibt auch eine Abstufung zwischen diesen beiden Zuständen an. Bei BAETGE (1996) werden die Unternehmen nach der Höhe des N-Werts entweder in eine von sechs Güteklassen für die finanzielle Stabilität oder in eine von vier Risikoklassen für den finanziellen Gefährdungsgrad eingestuft.

Probleme bei der Abstufung des finanziellen Zustandes sind nicht die Unterscheidungen zwischen einer hohen und einer sehr hohen Gefährdung, genauso wenig wie zwischen einem guten und sehr guten gesunden finanziellen Zustand. Besondere Aufmerksamkeit sollte vielmehr der Abstufung zwischen einem ausreichend gesunden finanziellen Zustand und einem leicht gefährdeten finanziellen Zustand gewidmet werden. Bei einer Kreditvergabe wird sich der Kreditgeber kaum Gedanken darüber machen, ob ein hoch gefährdetes oder ein sehr hoch gefährdetes Unternehmen keinen Kredit mehr erhält. Auch der Zusammenhang zwischen dem Rating eines Unternehmens und der Rendite ist nicht linear. Die Kosten für Unternehmensanleihen steigen nicht linear mit den Einstufungen durch Rating Agenturen.

Aus diesen Gründen reicht die Einteilung der Unternehmen in zwei Klassen "finanziell gefährdet" und "finanziell gesund" mit einer detaillierten Feinabstufung im Grenzbereich dieser beiden Klassen aus.

4.2.5 Aufbau des Fuzzy Systems

Bei der Einteilung von Jahresabschlüssen in zwei Klassen sind gerade die Jahresabschlüsse von Bedeutung, die nicht eindeutig zugeordnet werden können, weil sie zwischen diesen beiden Klassen liegen. Hier wird daher ein FS verwendet.

Für den Aufbau eines FS müssen zuerst die eingehenden Variablen fuzzifiziert werden. Dies ist in Kapitel 3.5 beschrieben worden. Weiter müssen Regeln anhand von Expertenwissen aufgestellt werden. Die Fuzzy-Regeln müssen so formuliert werden, dass anhand der drei Kennzahlen der finanzielle Zustand beschrieben werden kann.

Hierfür werden die theoretischen Zusammenhänge zwischen den Kennzahlen Gesamtkapitalrentabilität, dynamischer Verschuldungsgrad und Fremdkapitalanteil und dem Ereignis der "finanziellen Gefährdung" näher analysiert. In Kapitel 4.1.4.1 wurde dargelegt, warum diese drei Kennzahlen die finanzielle Situation des Unternehmens gut beschreiben.

Die Auswahl der Kennzahlenkombination zur Klasseneinteilung ist mit vielen Problemen behaftet. Ein überwachtes Lernen kann in diesem Fall nicht stattfinden, weil keine Outputdaten vorliegen. Die Ausprägung "finanziell gefährdet" ist nicht eindeutig empirisch für das Unternehmen erfassbar.

Die theoretischen Wechselwirkungen sind zwar zwischen den Kennzahlen bekannt, aber es existieren keine speziellen mathematische Funktionen darüber, wieviel die Gesamtkapitalrentabilität sich verändert, wenn der Fremdkapitalanteil und dynamische Verschuldungsgrad sich ändern.

Ein Problem besteht darin, dass bei einer höheren Rentabilität gleichzeitig sich das Risiko der finanziellen Gefährdung erhöht. Aber eine ausreichende Rentabilität ist eine notwendige Bedingung für eine dauerhaft finanziell gesunde Produktion und langfristig ein wichtiges Unternehmerziel. Bei der Festlegung der Fuzzy-Regeln muss berücksichtigt werden, bei welcher Kennzahlenkombination eine finanzielle Gefährdung vorliegt. Bei landwirtschaftlichen Unternehmen kann das Ereignis der finanziellen Gefährdung nicht anhand eines einzigen Kriteriums beschrieben werden. Dieses kann nur annäherungsweise über mehrere Kennzahlen erfolgen.

Ein weiteres Problem ist der Leverage-Effekt. Hierdurch steigt das finanzielle Risiko überproportional zum Anstieg der Rentabilität (SPREMANN, 1996, S. 301ff.). Das Risiko kann unterschieden werden in (BARRY et al., 2000, S. 172ff.):

- Anstieg der Hebelwirkung des Leverage-Effektes,
- Vorrangiger Verlust des Eigenkapitals,
- Überproportionale Einschränkung der Liquiditätsreserve.

Da nicht die Eigenkapitalrentabilität als Output-Variable berücksichtigt werden kann, und die Rentabilitätskennzahl alleine aus der Gesamtkapitalrentabilität resultiert, besteht die Gefahr, dass bei fallenden Rentabilitäten die Eigenkapitalrentabilität entsprechend des Hebels des Leverage-Effektes überproportional betroffen ist. Die hierdurch entstehenden Verluste müssen alleine durch das Eigenkapital gedeckt werden. Dieses wird dann überproportional reduziert. Dementsprechend ist die Beschreibung der finanziellen Gesundheit anhand der Kennzahl Gesamtkapitalrentabilität im Zusammenhang mit dem Fremdkapitalanteil besonders zu berücksichtigen.

Weil Unternehmen mit hohen Rentabilitäten hohe Risiken tragen, die wiederum überproportional stark von dem Unternehmer zu tragen sind (KASTENS und FEAHTERSTONE, 1999, S.20), existieren keine linearen Beziehungen zwischen der Gesamtkapitalrentabilität und der finanziellen Gesundheit von Unternehmen. Um diese

nicht linearen Beziehungen zwischen den drei Output-Kennzahlen zu berücksichtigen werden Fuzzy Regeln aufgestellt.


Der Zustand der finanziellen Gefährdung kann am besten durch linguistischen Variablen beschrieben werden. Für jede der Kennzahlen existieren die linguistischen Fragmente überdurchschnittlich, durchschnittlich und unterdurchschnittlich (Tab. 19) Der finanzielle Zustand kann durch die in Tab. 19 aufgeführten Regelbasis der Fragmente definiert werden.

Folgendermaßen werden diese Regeln formuliert: Für "Regel 1":

Wenn die Gesamtkapitalrentabilität "*überdurchschnittlich*" und

der Fremdkapitalanteil "*überdurchschnittlich*" und

der dynamische Verschuldungsgrad "*überdurchschnittlich*" ist,



dann ist die finanzielle Gesundheit des Unternehmens "*gesund*"

Für die restlichen Zeilen der Tab. 19 wird in gleicher Weise eine Regel formuliert.

Folgende Auswahlkriterien sind für die Einteilung der finanziellen Zustände bei den Regeln verwendet worden:

1. für "*finanziell gefährdete*" Unternehmen müssen folgende Bedingungen erfüllt sein: Das Unternehmen wird bei mindestens zwei Kennzahlen als unterdurchschnittlich eingestuft oder zwei Kennzahlen als durchschnittlich und die dritte als unterdurchschnittlich.
2. für "*finanziell gesunde*" Unternehmen: Alle als *nicht* "finanziell gefährdete" eingeteilte Unternehmen.

TAB. 19: REGELN FÜR DIE BESCHREIBUNG DER FINANZIELLEN SITUATION

Regel Nr.	Gesamtkapitalrentabilität	Fremdkapitalanteil ¹⁾	dynamischer Verschuldungsgrad	Finanzieller Zustand
1	ÜBERDURCHSCHNITTLICH	ÜBERDURCHSCHNITTLICH	ÜBERDURCHSCHNITTLICH	Gesund
2	ÜBERDURCHSCHNITTLICH	ÜBERDURCHSCHNITTLICH	DURCHSCHNITTLICH	Gesund
3	ÜBERDURCHSCHNITTLICH	DURCHSCHNITTLICH	ÜBERDURCHSCHNITTLICH	Gesund
4	DURCHSCHNITTLICH	ÜBERDURCHSCHNITTLICH	ÜBERDURCHSCHNITTLICH	Gesund
5	ÜBERDURCHSCHNITTLICH	DURCHSCHNITTLICH	DURCHSCHNITTLICH	Gesund
6	DURCHSCHNITTLICH	DURCHSCHNITTLICH	ÜBERDURCHSCHNITTLICH	Gesund
7	DURCHSCHNITTLICH	ÜBERDURCHSCHNITTLICH	DURCHSCHNITTLICH	Gesund
8	ÜBERDURCHSCHNITTLICH	ÜBERDURCHSCHNITTLICH	UNTERDURCHSCHNITTLICH	Gesund
9	UNTERDURCHSCHNITTLICH	ÜBERDURCHSCHNITTLICH	ÜBERDURCHSCHNITTLICH	Gesund
10	ÜBERDURCHSCHNITTLICH	UNTERDURCHSCHNITTLICH	ÜBERDURCHSCHNITTLICH	Gesund
11	DURCHSCHNITTLICH	DURCHSCHNITTLICH	DURCHSCHNITTLICH	Gesund
12	ÜBERDURCHSCHNITTLICH	DURCHSCHNITTLICH	UNTERDURCHSCHNITTLICH	Gesund
13	ÜBERDURCHSCHNITTLICH	UNTERDURCHSCHNITTLICH	DURCHSCHNITTLICH	Gesund
14	DURCHSCHNITTLICH	ÜBERDURCHSCHNITTLICH	UNTERDURCHSCHNITTLICH	Gesund
15	DURCHSCHNITTLICH	UNTERDURCHSCHNITTLICH	ÜBERDURCHSCHNITTLICH	Gesund
16	UNTERDURCHSCHNITTLICH	ÜBERDURCHSCHNITTLICH	DURCHSCHNITTLICH	Gesund
17	UNTERDURCHSCHNITTLICH	DURCHSCHNITTLICH	ÜBERDURCHSCHNITTLICH	Gesund
18	ÜBERDURCHSCHNITTLICH	UNTERDURCHSCHNITTLICH	UNTERDURCHSCHNITTLICH	Gefährdet
19	UNTERDURCHSCHNITTLICH	ÜBERDURCHSCHNITTLICH	UNTERDURCHSCHNITTLICH	Gefährdet
20	UNTERDURCHSCHNITTLICH	UNTERDURCHSCHNITTLICH	ÜBERDURCHSCHNITTLICH	Gefährdet
21	DURCHSCHNITTLICH	UNTERDURCHSCHNITTLICH	DURCHSCHNITTLICH	Gefährdet
22	DURCHSCHNITTLICH	DURCHSCHNITTLICH	UNTERDURCHSCHNITTLICH	Gefährdet
23	UNTERDURCHSCHNITTLICH	DURCHSCHNITTLICH	DURCHSCHNITTLICH	Gefährdet
24	DURCHSCHNITTLICH	UNTERDURCHSCHNITTLICH	UNTERDURCHSCHNITTLICH	Gefährdet
25	UNTERDURCHSCHNITTLICH	DURCHSCHNITTLICH	UNTERDURCHSCHNITTLICH	Gefährdet
26	UNTERDURCHSCHNITTLICH	UNTERDURCHSCHNITTLICH	DURCHSCHNITTLICH	Gefährdet
27	UNTERDURCHSCHNITTLICH	UNTERDURCHSCHNITTLICH	UNTERDURCHSCHNITTLICH	Gefährdet

1) überdurchschnittlich: Unternehmen mit einem geringen Fremdkapitalanteil

Die Auswahlkriterien für diese Klasseneinteilung sind folgende: Unternehmen, die keine unterdurchschnittliche Einstufung sowohl in der Rentabilität wie auch in der Stabilität ausweisen, sind zumindest finanziell ausgewogen mit geringeren finanziellen Schwächen im Vergleich zu anderen Unternehmen. Dagegen sind Unternehmen, die zwei unterdurchschnittliche Kennzahlen aufweisen kritisch zu beurteilen, da die verbleibenden Kennzahlen (Gesamtkapitalrentabilität, dynamischer Verschuldungsgrad und Fremdkapitalanteil) nicht ausreichen, um die anderen beiden annähernd auszugleichen. Auch zwei durchschnittliche Ausprägungen reichen nicht aus, eine dritte unterdurchschnittliche auszugleichen. Beispielsweise ist ein Unternehmen mit einer geringen Gesamtkapitalrentabilität und einem geringen dynamischen Verschuldungsgrad nicht in der Lage, durch einen niedrigen Fremdkapitalanteil die anderen beiden Kennzahlen auszugleichen.

Es existieren inhaltliche Abhängigkeiten zwischen den drei Kennzahlen, die vermuten lassen, dass bestimmte Regeln häufiger zutreffen als andere. Zum einen würde man davon ausgehen, dass ein höherer Fremdkapitalanteil zu einer größeren Rentabilität führt (s.o.). Zum anderem ist das Fremdkapital sowohl Bestandteil der Kennzahl Fremdkapitalanteil wie auch des dynamischen Verschuldungsgrades. Aber die Auswertung einer Korrelationsmatrix ergibt folgendes Bild:

TAB. 20: KORRELATIONSMATRIX

Korrelationsmatrix	Gesamtkapitalrentabilität	Fremdkapitalanteil	Dynamischer Verschuldungsgrad
Gesamtkapitalrentabilität	1	- 0,11	0,06
Fremdkapitalanteil	- 0,11	1	- 0,06
Dynamischer Verschuldungsgrad	0,06	- 0,06	1

Quelle: Eigene Berechnungen

Diese Korrelationswerte liegen maximal bei 0,11. Dies besagt, dass keine Korrelationen zwischen den Kennzahlen vorliegt.

Die 27 Regeln decken jede Kombinationsmöglichkeit der drei Kennzahlen ab. Die Häufigkeit der verwendeten Regeln ist aber sehr unterschiedlich.

TAB. 21: KOMBINATIONSMÖGLICHKEITEN DER REGELN

Häufigkeit	Unter 3 %	Zwischen 3% und 10 %	Über 10 %
Anzahl	5	10	12
Regel Nr.	1, 4, 9, 21, 27	2, 3, 13, 17, 18, 22, 23, 24, 25, 26	5, 6, 7, 8, 10, 11, 12, 14, 15, 16, 19, 20

Quelle: Eigene Berechnungen

Die beiden Extremregeln 1 und 27 treten nur selten auf (vgl. Tab. 21). Es gibt fast keine Unternehmen, die eine gleichzeitige Zugehörigkeit größer als Null bei dem Fragment überdurchschnittlich für alle drei Kennzahlen aufweisen. Das gleiche gilt für das Fragment unterdurchschnittlich.

Ein Drittel aller Häufigkeiten des Resultats "finanziell gefährdet" treten durch die Regeln Nr. 19 und 20 auf. Diese besagen, dass jeweils zwei unterdurchschnittliche und ein überdurchschnittliches Fragment vorliegen, wobei die Gesamtrentabilität einen unterdurchschnittlichen Zustand aufweist. 40 Prozent der Zugehörigkeit der Klasse "gefährdet" ist auf die Kennzahl der Gesamtrentabilität zurückzuführen. Hierdurch hat diese Kennzahl einen höheren Erklärungsbeitrag bei der Klassifizierung als die anderen beiden Kennzahlen.

Auswahl der Fuzzy Mengen Operatoren

Nachdem die Regeln für das FS aufgestellt worden sind, müssen für die Berechnung der eingesetzten Regeln Fuzzy-Mengen Operatoren ausgewählt werden. Die Verknüpfungen der Zugehörigkeiten können auf unterschiedlicher Weise erfolgen (vgl. Kapitel 3.5.3). Die hier verwendete Operatoren muss folgende Eigenschaften aufweisen:

1. kompensatorische Wirkung
2. abnehmende kompensatorische Wirkung an den Eckpunkten
3. kompensatorische Wirkung für drei unabhängige Variablen

Folgender Operator erfüllt diese Bedingungen am besten:

$$m_{und}(m_1(x), m_2(x), m_3(x)) = g \cdot \min(m_1(x), m_2(x), m_3(x)) + (1-g) \cdot \frac{m_1(x) + m_2(x) + m_3(x)}{3},$$

mit m_1 = Gesamtkapitalrentabilität


m_2 = Fremdkapitalanteil

m_3 = dynamischer Verschuldungsgrad

g = Kompensationsfaktor mit $g=0,5$

Dieser Kompensationsoperator hat folgende kompensatorische Wirkung:

ABB. 50: KOMPENSATORISCHE WIRKUNG FÜR ZWEI OUTPUT-VARIABLEN



Quelle: Eigene Darstellung

In der Abb. 50 ist die kompensatorische Wirkung für zwei Variablen bei der hier verwendeten Operation graphisch dargestellt. Die Abbildung aller drei Output-Variablen ist räumlich nicht möglich. Aus diesem Grund wird die Output-Variable dynamischer Verschuldungsgrad konstant auf 1 festgelegt.

Klassenzugehörigkeiten von annähernd Null und Null haben eine geringere Wirkung auf das Gesamtergebnis als Werte größer als 0,5. Die Ausprägung dieser Wölbung ist abhängig von dem Kompensationsfaktor g . Beträgt dieser 0,5, so werden die mittleren Ausprägungen gegenüber den Randwerten übergewichtet. Aus diesem

Grund ist diese Kompensation geeignet für die Operation der drei Output-Variablen. Unternehmen, die in allen drei Kennzahlen durchschnittliche Werte aufweisen, sind finanziell besser zu beurteilen als Unternehmen mit sehr guten und sehr schlechten Werten. Diese lassen sich zwar kompensieren, aber je weiter sie auseinander liegen desto geringer ist die Kompensation.

Da im allgemeinen mehr als eine Regel zutrifft, müssen diese zu einem Gesamturteil zusammen gefasst werden. Dies wird durch die Zusammenfassung der Erfüllungsgrade nach folgender Formel durchgeführt (vgl. Kapitel 3.5.4):

$$\text{Erfüllungsgrad der Regel}_{\text{Bewertung}} = \left[1 - \prod (1 - \text{Erfüllungsgrad der Regel}_{\text{Regel } i}) \right]$$

Durch diese Zusammenfassung der Regeln erfolgt eine gleichmäßige Gewichtung der Erfüllungsgrade der verschiedenen Regeln. Hierdurch entsteht nur "ein" Zugehörigkeitswert für jede der beiden Klassen "finanziell gefährdet" und "finanziell gesund".

Um später eine Defuzzifizierung vornehmen zu können, müssen im nächsten Schritt die Erfüllungsgrade für alle Regeln der Fuzzy-Mengen auf den finanziellen Zustand des Unternehmens projiziert werden. Hierfür kann die Max-Prod-Inferenz Methode verwendet werden (vgl. Kapitel 3.5.4). Diese wird dem Max-Min-Inferenz Verfahren vorgezogen, weil bei dieser niedrigere und mittlere Erfüllungsgrade stärker gewichtet werden.


Die durch die Max-Prod-Inferenz Verfahren gewonnen Werte werden danach defuzzifiziert. Da die vorliegenden Flächen nur sehr schlecht interpretiert werden können, wird mit Hilfe der Flächenschwerpunktmethod (CoM) ein Wert ermittelt, der die Flächen zu einem Wert zusammenfasst. Dieser Wert kann als eine Art Grad der relativen finanziellen Gefährdung interpretiert werden.

4.3 Ermittlung der Klassifizierungsergebnisse

Zuerst werden für die Jahresabschlüsse aus dem Wj 1996/97 durch das in Kapitel 4.2 beschriebene FS die jeweiligen Zugehörigkeitswerte der Klassen "finanziell gefährdet" und "finanziell gesund" errechnet. Danach werden anhand der Input-Daten (Wj 1991/92, 92/93 und 93/94 vgl. Kapitel 4.1.2) mit Hilfe der trainierten NN für jedes Unternehmen die Werte für die drei Output-Kennzahlen ermittelt. Hierbei handelt es sich um Zugehörigkeitswerte zu den linguistischen Fragmenten überdurchschnittlich, durchschnittlich und unterdurchschnittlich. Durch diese Werte werden wiederum mittels das in Kapitel 4.2 beschriebene FS die Unternehmen der jeweiligen Klasse zugeordnet.

Bei einer unscharfen Klassifizierung, wie im FNN-Modell, werden die Zugehörigkeitswerte zu den einzelnen Klassen ermittelt. Hieraus kann der Zugehörigkeitsgrad der jeweiligen Klasse abgeleitet werden.

ABB. 51: ZUGEHÖRIGKEITSFUNKTIONEN DER KLASSEN FINANZIELL GEFÄHRDET UND GESUND



Quelle: Eigene Darstellung

In Abb. 51 erfolgt eine Zuteilung der Zugehörigkeitswerte des finanziellen Zustandes zu den einzelnen Klassen. Zugehörigkeitswerte von 1 und 0 können eindeutig zugeordnet werden. Aus diesem Grund können eindeutige Aussagen über Unternehmen mit diesen Zugehörigkeiten abgeleitet werden. Folgendermaßen werden die Zugehörigkeiten interpretiert:

- Bei Unternehmen mit einer Zugehörigkeit von 1 für die Klasse "finanziell gefährdet" (bzw. 0 für finanziell gesund) liegt in 3 Jahren unter den gleichen Rahmenbedingungen eine finanzielle Gefährdung vor.
- Bei Unternehmen mit einer Zugehörigkeit von 1 für die Klasse "finanziell gesund" (bzw. 0 für finanziell gefährdet) liegt in 3 Jahren unter den gleichen Rahmenbedingungen keine finanzielle Gefährdung vor.

Zugehörigkeiten zwischen 0 und 1 können nicht eindeutig zugeordnet werden. Sie liegen in einem "unscharfen Bereich" (vgl. Abb. 51). Für diese Unternehmen kann keine eindeutige Aussage abgeleitet werden, wie ihr finanzieller Zustand nach 3 Jahren sein wird. Aufgrund der Höhe der Zugehörigkeiten können lediglich Tendenzen über die finanzielle Entwicklung abgeleitet werden.

Durch die Klassifizierung erhält das landwirtschaftliche Unternehmen die Information, wie die betriebliche finanzielle Situation im Verhältnis zu den anderen Mitbewerbern sich in den nächsten Jahren entwickelt. Diese Information ist für den Unternehmer insofern wichtig, da durch Preis- und Politikeinflüsse sich der Wettbewerb unter den landwirtschaftlichen Unternehmen verschärfen kann. Nur die Unternehmen werden zukünftig überleben, deren finanzielle Situation besser ist als die der Konkurrenz. Deshalb wird es für die Unternehmen wichtiger, frühzeitig finanzielle Fehlentwicklungen zu erkennen. Beispielsweise führt die Milchquotenbörse zu einem höheren Wettbewerb. Zukünftig können vor allem die Unternehmen Milchquote zukaufen, deren finanzielle Situation besser ist als die der Mitbewerber. Durch die Ergebnisse des FNN-Modells liegen dem Unternehmen Informationen darüber vor, wie sich das Unternehmen im Vergleich zu anderen Unternehmen entwickeln wird.

Bestimmung der Klassifizierungsgüte

Die Testmenge für die Bestimmung der Klassifizierungsgüte enthält 810 Datensätze (15 %-Anteil), die aus der Gesamtmenge der Futterbaubetriebe als Testmenge ausselektiert wurde (vgl. Kapitel 4.1.2). Diese Datensätze sind bisher nicht für die Modellentwicklung verwendet worden, sondern dienen zur Überprüfung der Funktions- und Leistungsfähigkeit des FNN-Modells. Anhand dieser Testmenge wird überprüft, wie die Klassifizierungsleistung des Modells für unbekannte Datensätze ist. Bei der Klasseneinteilung der finanziellen Gefährdung für die Buchführungsdaten (Wj 96/97) sind 47% der Unternehmen als finanziell gesund, 20% als finanziell gefährdet und 33% als unsicher (unscharfer Bereich) eingestuft worden.

Die zwei ermittelten Zugehörigkeitswerte für jedes Unternehmen werden miteinander verglichen. Hierbei handelt es sich um Zugehörigkeitswerte, die einmal aus den Buchführungsdaten (Wj 96/97) und zum anderen aus dem FNN-Modell abgeleitet werden. Für die Bestimmung der Klassifizierungsgüte können die Abweichungen der beiden Zugehörigkeiten eines Unternehmens berechnet werden. Diese Abweichungen können als mittleren quadratischen Fehler (MSE) der Zugehörigkeiten ermittelt werden. Der MSE-Wert beträgt 0,14. Dieser Wert kann im Vergleich zu anderen Klassifizierungsinstrumenten nicht ausreichend interpretiert werden.

Für eine weitere Untersuchung werden die Zugehörigkeitswerte den einzelnen Klassen "finanziell gefährdet", "finanziell gesund" und "unscharfer Bereich" vollständig zugeordnet. In Tab. 22 sind die Übereinstimmung der Klassen aufgeführt. Aus dieser

Untersuchung ist ersichtlich, dass die Klasse "finanziell gesund" mit einer 97,5 %igen und die Klasse "finanziell gefährdet" mit einer 92,6 %igen Richtigkeit eine gute Übereinstimmung zwischen den tatsächlich vorliegenden Werten und den mit den FNN-Modell ermittelten Klassen aufweist. In dem unscharfen Bereich liegt die Übereinstimmung bei 56,1 %. Für diesen Bereich ist die Klassifizierungsleistung sehr unbefriedigend. Für Unternehmen, die im "unscharfen Bereich" liegen, können somit keine eindeutige Aussagen über ihren zukünftigen finanziellen Zustand abgeleitet werden.

TAB. 22: KLASSIFIZIERUNGSERGEBNISSE

Übereinstimmung der Klassen in Prozent			
FNN-Modell²⁾ Daten¹⁾	Finanziell gefährdet	Unscharfer Bereich	Finanziell gesund
Finanziell gefährdet	92,6 %	20,8 %	1,1 %
Unscharfer Bereich	4,1 %	56,1 %	1,4 %
Finanziell gesund	3,3 %	23,1 %	97,5 %

1) Zugehörigkeitswerte aus den Buchführungsdaten (Wj 96/97)
2) Zugehörigkeitswerte aus dem FNN-Modell

Quelle: Eigene Darstellung

Des weiteren kann aus Tab. 22 abgeleitet werden, dass die fehlassifizierten Unternehmen nicht unbedingt in die Nachbarklasse klassifiziert worden sind. Falsch klassifizierte Unternehmen weisen häufig stark abweichende Kennzahlenmuster auf.

Gründe für Fehlassifizierungen

Bei einer genaueren Analyse der fehlassifizierten Unternehmen weist der größte Teil (über 62 % der Unternehmen) Sondereinflüsse auf, die anhand der vorhandenen Jahresabschlüsse nicht erkennbar waren. Dieses waren entweder größere Wachstums- oder Abstockungsschritte und/oder unerwartete hohe Privateinlagen oder -entnahmen. Der größte Teil der Fehlassifizierung ist somit nicht auf das Klassifizierungsinstrument zurückzuführen, sondern auf die Datengrundlage für die Beurteilung des finanziellen Zustandes der Unternehmen.

Hier liegt ein Verstoß gegen die Prämisse der Zeitstabilität des Modells vor. Diese Prämisse ist bei einer dynamischen Entwicklung der Unternehmen nicht erfüllbar. 3-jährige Durchschnitte und die Entwicklung von Kennzahlen über 3 Jahren können zwar teilweise Abhilfe schaffen, aber hieraus können nicht die zukünftigen Entwicklungen abgeleitet werden, weil sich auch die Entwicklung der Unternehmen von Jahr zu Jahr

ändert. Die Unternehmen, die sich auf unterschiedliche Entwicklungspfade, wie Wachstum oder Abstockung befinden, weisen in den Jahresabschlüssen keine kontinuierlichen Veränderungen auf.

Die meisten in dieser Arbeit verwendeten Datensätze stammen von Familienunternehmen. Hier besteht eine enge Verflechtung zwischen dem Unternehmen und der Familie sowie dem Privat- und Betriebsvermögen (BODMER, 2001, S. 9). Die Buchführungsdaten, die für diese Klassifizierung verwendet worden sind, stammen aus dem betrieblichen Teil eines privaten Gesamtvermögens. Bei diesen Familieneinheiten erfolgt ein ständiger Austausch von Kapital zwischen den einzelnen Vermögensbereichen. Dieser Kapitalfluss für das landwirtschaftliche Unternehmen ist zwar anhand der Einlagen und Entnahmen nachvollziehbar, aber es bestehen keine Informationen darüber, wie hoch das Potential für Einlagen aus anderen Teilbereichen ist.

Gründe für die Aufteilung der Klassifizierung

Die Aufteilung des Klassifizierungsmodells in einen lernenden Teil und der Zusammenführung der Output-Kennzahlen zu einem Ereignis verbessert die Klassifizierungsergebnisse.

Grundsätzlich gibt es mehrere Arten finanziell gefährdeter Unternehmen mit unterschiedlichen Kennzahlenmustern:

- Unternehmen mit einer hohen Verschuldung aufgrund von Wachstumsschritten
- Unternehmen mit einer schlechten Kapitalrentabilität ohne Wachstum

Bei der korrekten Klassifizierung der Unternehmen in die jeweilige Klasse führt dies dazu, dass ein empirisch-induktives Klassifizierungsinstrument zwei grundsätzlich unterschiedliche Kennzahlenmuster zu dem gleichen Ereignis klassifizieren muss.

Die Diagnose des finanziellen Zustandes der Unternehmen erfolgt, indem die Werte der Input-Variablen mit den Gewichten (NN) bewertet und zu einem Wert zusammengeführt werden. Beim Lernen der Gewichte kommt es durch die unterschiedlichen Ursachen der finanziellen Gefährdung zu Verzerrungen bei den Kennzahlenmustern.

Die Aufteilung des Klassifizierungsmodells in NN und FS führt dazu, dass das NN nicht das Gesamtereignis klassifizieren muss, sondern nur eine Kennzahl. Die Klassifizierung einer Kennzahl ist jedoch unabhängig von der Ausprägung der beiden anderen. Somit müssen nur die Wechselwirkungen zwischen einer Output-Kennzahl und den jeweiligen Input-Kennzahlen durch das NN gelernt werden.

Vorteile durch die Verwendung von Fuzzy Mengen

Durch die Verwendung von Fuzzy Mengen erfolgt keine scharfe Abgrenzung zwischen den "finanziell gesunden" und "finanziell gefährdeten" Unternehmen. Es wird für jedes Unternehmen ein Wert für den Zugehörigkeitsgrad zur jeweiligen Klasse ermittelt.

Der Zugehörigkeitsgrad liefert die zusätzliche Information, wie hoch der Grad der finanziellen Gefährdung des Unternehmens ist. Außerdem können die Unternehmen ermittelt werden, die nicht eindeutig der einen oder anderen Klasse zugeordnet werden können.

4.4 Fazit

Es kann festgehalten werden, dass das Modell als Klassifizierungsinstrument zu guten Ergebnissen führt. Es ist allerdings nicht in der Lage, nicht vorhandene, aber benötigte Informationen aus den Jahresabschlüssen herauszufiltern. Die Klassifizierungsgüte ist maximal so gut wie die vorhandenen Informationen in den Jahresabschlüssen.

Für eine bessere Klassifizierungsgüte ist es deshalb notwendig, die vorhandenen Daten um die jeweilig relevanten Informationen zu erweitern. Dieses ist bei dieser Arbeit nicht möglich, da die verwendeten Datensätze aus Jahresabschlüssen stammen und keine weiteren Informationen über die Unternehmen vorliegen.

Mit der vorhandenen Datengrundlage können keine Aussagen über die Kreditwürdigkeit eines Unternehmens, das ein größeres Kreditvolumen für Investitionen benötigt, gemacht werden. Diese Investitionen führen zu einem veränderten finanziellen Zustand des Unternehmens, der anhand von vergangenheitsbezogenen Buchführungsdaten nicht klassifiziert werden kann.

Die Entwicklung eines Kreditwürdigkeitsprüfungsmodells könnte mit dem gleichen Modellaufbau erfolgen, aber mit einer anderen Datengrundlage. Hierfür müsste das FNN-Modell mit Daten von Unternehmen trainiert werden, die kurz nach der Prüfung einen Kredit aufgenommen und diesen für eine landwirtschaftliche Investition genutzt haben. Außerdem müssten noch weitere Informationen über die Investition vorliegen. Es müsste insbesondere der Investitionsgegenstand bekannt sein.

Da in dieser Arbeit in der Datengrundlage keine politischen, volkswirtschaftlichen, gesellschaftlichen und marktwirtschaftlichen Daten mit einfließen, ist es auch nicht möglich bzw. sinnvoll, anhand dieser Daten Aussagen über die zukünftige Entwicklung des landwirtschaftlichen Sektors zu treffen. Um Aussagen über die Auswirkungen von politischen Einflüsse zu machen, muss ein NN mit den hierfür relevanten Daten trainiert werden.

Das hier entwickelte FNN-Modell mit der vorhandenen Datengrundlage kann als ein **Kontrollinstrument für die Früherkennung der finanziellen Zustände** von landwirtschaftlichen Unternehmen eingesetzt werden. Durch dieses Modell erhalten die Unternehmen zusätzliche Informationen darüber, wie ihre finanzielle Stabilität gegenüber den anderen landwirtschaftlichen Unternehmen ist.

Ob das FNN-Modell bessere Klassifizierungsergebnisse liefert als bisherige Instrumente, kann nur ein Vergleich mit diesen Klassifizierungsinstrumenten liefern. Hierfür müssen die hier verwendeten Jahresabschlüsse durch diese Instrumente klassifiziert und anschließend verglichen werden. In Kapitel 5 wird dieser Vergleich vorgenommen und die Ergebnisse vorgestellt und interpretiert.

5 Vergleich Fuzzy Neuronaler Netze mit einer Diskriminanzanalyse

In diesem Kapitel wird ein Vergleich zwischen dem FNN-Modell und den bisher gebräuchlichen Klassifizierungsinstrument der Diskriminanzanalyse durchgeführt. Bei diesem Vergleich werden neben der Klassifizierungsgenauigkeit weitere Vor- und Nachteile dieser Klassifizierungsinstrumente herausgearbeitet.

Die Klassifizierung mit Hilfe des FNN-Modells ist für eine jährliche Kontrolle der finanziellen Zustände der Unternehmen geeignet. Aber anhand der Ergebnisse ist nicht ableitbar, ob dieses Instrument eine bessere Klassifizierungsleistung liefert als die bisherigen Instrumente. Um beurteilen zu können, ob dieses Modell eine Verbesserung gegenüber bisherigen empirisch-induktiven Verfahren aufweist, werden die vorliegenden Ergebnisse mit Ergebnissen von ähnlichen Verfahren verglichen.

5.1 Auswahl der Vergleichsmethode

In den letzten 20 Jahren wurde eine Vielzahl von Frühwarnsystemen und Kreditwürdigkeitsprüfungsinstrumente entwickelt, die auf einer empirisch-induktiven Klassifizierung basieren. Diese sind bei ALTMAN und SAUNDERS (1998) chronologisch zusammengefasst worden. Hier wird eine Vielzahl von Benchmarks für dieses Modell beschrieben.

Die Vergangenheit hat gezeigt, dass eine Entwicklung weg von der subjektiven Unternehmensanalyse durch Personen hin zu objektiveren Analysen erfolgt ist. Neben Kostenersparnissen durch diese Instrumente entfällt die subjektive Bewertung durch eigene Interessen. Beispielsweise tendieren Experten der Bank bei einer Kreditwürdigkeitsprüfung zur einer pessimistischen Einstellung, um eigene Fehler zu vermeiden (vgl. ALTMAN und SAUNDERS, 1998). Mittlerweile sind auch die multivariaten credit-scoring Modelle bei der Abschätzung von Unternehmensentwicklungen den Experten bei gleicher Informationsbasis überlegen (ALTMAN und SAUNDERS, 1998).

Bei der Verwendung der Jahresabschlussanalyse in der traditionellen Kennzahlenanalyse als Überwachungsinstrument werden die Kennzahlen mit Normgruppen oder Soll-Zuständen verglichen. Bei den späteren multivariaten Modellen wurden die einzelnen Kennzahlen gewichtet und zu einem Wert verdichtet. Dieser Wert wurde dann mit einem Benchmarkwert verglichen und gefolgert, wie der finanzielle Zustand des Unternehmens ist.

Die bisher größte Anzahl an statistischen Kreditwürdigkeitsprüfungsmodellen und Frühwarnsystemen basieren bis heute auf Regressions- und Diskriminanzanalysen. Regressionsanalytische Ansätze sind das lineare Wahrscheinlichkeitsmodell, die Logit- und die Probit-Analyse. Bei der Regressionsanalyse wird eine Kombination von

Kennzahlen gesucht, die die dichotome, abhängige Variable möglichst gut erklärt. Bei den einzelnen regressionsanalytischen Ansätzen werden unterschiedliche Beziehungen zwischen den unabhängigen Kennzahlen und den abhängigen Variablen unterstellt. Die Kennzahlen sind dabei nicht an die Voraussetzungen der Normalverteilung für die Ausprägung gebunden. Die Klassifizierungsleistung der regressionsanalytischen Ansätze wird in empirischen Vergleichsstudien sehr unterschiedlich beurteilt und deshalb hier nicht als Benchmark gewählt.

Aufgrund der bisherigen umfangreichen empirischen Analysen von statistischen Jahresabschlussanalysen und der ähnlichen Funktionsweise wird als Vergleich die Diskriminanzanalyse gewählt. Verteilungsfreie Ansätze der Diskriminanzanalyse sind das Kendall-, das Linhart-, das Nearest-Neighbour-Verfahren und die Kern-Methode. Diese Verfahren sind bisher nur vereinzelt eingesetzt worden. Die hiermit durchgeführten Untersuchungen zeigten bisher unbefriedigende Ergebnisse.

Die verteilungsabhängigen Ansätze der Diskriminanzanalyse sind die quadratische und die lineare Diskriminanzanalyse. Da die quadratische Diskriminanzanalyse eine Vielzahl von Nachteilen aufweist, wird in dieser Untersuchung die lineare multivariate Diskriminanzanalyse (MDA) als Benchmark gewählt. Durch ihre gute wissenschaftliche Erforschung seit der Einführung des sogenannten "Zeta-Modell" von ALTMAN et al. (1977) und der ständigen Weiterentwicklung dieses Modells ist heute die MDA ein anerkannter Benchmark für die Vergleichbarkeit mit neueren Ansätzen.

Für den Vergleich zwischen NN und MDA sind eine Vielzahl an Untersuchungen durchgeführt worden. Die Ergebnisse der Vergleiche können bei ERXLEBEN et al. (1992), BAETGE et al. (1992), KRAUSE (1993), REHKUGLER und ZIMMERMANN (1994), BURGER (1995), PYTLIK (1995) DESAI, CROOK und OVERSTREET (1995), TRIPPI und TURBAN (1996) HAFNER (1997) BARNEY, GRAVES und JOHNSON (1999) und WEST (2000) in einer großen Vielzahl nachgelesen werden.

5.2 Vergleich des Fuzzy Neuronalen Netzes mit einer Diskriminanzanalyse

Der hier durchgeführte Vergleich wird unterteilt in (vgl. Kapitel 4.3):

1. Vergleich zwischen dem FNN-Modell und der MDA
2. Vergleich zwischen dem Klassifizierungsteil "NN" und der MDA im FNN-Modell

Bisher durchgeführte Untersuchungen beziehen sich alle auf die Klassifizierung von Jahresabschlüssen, die nach verschiedenen Ereignissen vorgenommen wurden. Diese Ereignisse sind z.B. Kreditwürdigkeit und Insolvenz. Bei einem empirisch-induktiven Modell muss dieses Ereignis bei den Unternehmen auftreten und empirisch erfassbar sein. Treten diese Ereignisse bei diesen Unternehmen gar nicht oder nur in einem geringen Umfang auf, wie z.B. bei den landwirtschaftlichen Unternehmen die Insolvenz,

so können diese Unternehmen nicht nach diesen Ereignissen klassifiziert werden. Das Ereignis der finanziellen Gefährdung ist dem landwirtschaftlichen Unternehmen nicht eindeutig anzusehen, sondern dieses kann nur über die Betrachtung von verschiedenen Kennzahlen abgeleitet werden. Die Unternehmen sind nach dem FS den Klassen "finanziell gesund" und "finanziell gefährdet" zugeordnet worden. Die MDA klassifiziert die Unternehmen nach diesen Klassen. Des Weiteren wird die MDA für die Klassifizierung der Output-Variablen eingesetzt. Hier ersetzt sie die NN als Klassifizierungselement im FNN-Modell (vgl. Kapitel 4.3).

Die Ermittlung der Diskriminanzfunktion erfolgt anhand der Menge der Lerndaten (vgl. Kapitel 4.1.2). Als Testdaten dienen dieselben Unternehmen wie für das FNN-Modell. Die Daten der Validierungsmenge wurden in diesem Fall nicht berücksichtigt.

Folgende Klassifizierungsergebnisse erbrachte die MDA. Eine korrekte Klassifizierung der Unternehmen erfolgte für:

- 76,6 % bei der Klassifizierung nach 2 Klassen des finanziellen Zustandes
- 79,8 % bei der Klassifizierung der drei Outputvariablen und anschließenden FS.

TAB. 23: ERGEBNISSE DER MDA

Analyseinstrument	Anzahl der falsch klassifizierten Unternehmen	Klassifizierungsergebnis korrekt
FNN ¹⁾	140	82,7 %
MDA ²⁾	190	76,6 %
MDA und FS ³⁾	164	79,8 %

1) FNN-Modell klassifiziert nach 2 Klassen. Die Klassengrenze liegt bei einem Zugehörigkeitswert von 0,5
 2) MDA klassifiziert nach 2 Klassen.
 3) 3 verschiedene MDA klassifizieren nach der Gesamtkapitalrentabilität, Fremdkapitalanteil und dynamischen Verschuldungsgrad. Anschließend werden die drei Outputvariablen über ein FS zusammengeführt.

Quelle: Eigene Berechnungen

Bei diesem Vergleich liefert das FNN Modell mit 82,7 % korrekt klassifizierte Unternehmen das beste Ergebnis. Der Vergleich mit der MDA zeigt, dass diese ein um 6,1 Prozentpunkte schlechteres Klassifizierungsergebnis liefert (vgl. Tab. 23). Auch die Klassifizierung der drei Output-Variablen Gesamtkapitalrentabilität, dynamischer Verschuldungsgrad und Fremdkapitalanteil und die danach folgende Zusammenführung zu dem Ereignis der Finanzgefährdung führt zur einer schlechteren Klassifizierungsgüte von 2,9 Prozentpunkte.

5.2.1 Anwendungsvoraussetzungen für die MDA

Bei diesem Vergleich ist zu berücksichtigen, dass der eingehende Input-Kennzahlen Katalog voneinander abweicht (vgl. Tab. 11, 12, 13 und 14). Für die Anwendung der MDA sind verschiedene statistische Voraussetzungen notwendig (BURGER, 1995, S. 280ff.). Diese werden aber nicht von allen Inputvariablen erfüllt. Diese Anwendungsvoraussetzungen sind (FEIDICKER, 1992, S.70ff.):

- Normalverteilung
- Varianz-Homogenität
- Unabhängigkeit der Kennzahlen
- Trennfähigkeit der Kennzahlen

Ohne eingehende statistische Kenntnisse sind die Vielzahl der Voruntersuchungen, Vortests und deren Interpretationen für die MDA nicht möglich. Zunächst wird geprüft, ob bei den einzelnen Kennzahlen die Normalverteilung gegeben ist.

Die Prüfung der Kennzahlausprägungen anhand von Schiefe und Exzess zeigt die Symmetrie der Kennzahlenverteilung. Die Verteilungswerte für Schiefe und Exzess einer konkreten Kennzahl werden mit jenen der Normalverteilung verglichen. Bei der Gegenüberstellung erkennt man, ob eine Normalverteilung der Kennzahlwerte vorliegt.

Die Normalverteilung ist nur bei der Kennzahl Abnutzungsgrad der Maschinen K26 gegeben. Die restlichen Kennzahlen sind nicht normalverteilt. Damit werden die statistischen Voraussetzungen für die MDA nicht erfüllt. Die Folgen sind verzerrte Signifikanztests, verzerrte Fehlerraten und suboptimale Klassifizierungsraten. Auch die Untersuchung, ob die Varianzen der Kennzahlen bei den finanziell gefährdeten und den finanziell gesunden Unternehmen gleich hoch sind, die **Varianz-Homogenitäts-Annahme**, führt zu dem Ergebnis, dass diese Voraussetzung nicht erfüllt ist.

Trotz der Verletzung dieser beiden Anwendungsvoraussetzungen sind viele Klassifizierungen mit der MDA durchgeführt worden, die zu gleich guten oder sogar besseren Klassifizierungsergebnissen führen als bei anderen nicht-parametrischen Verfahren oder parametrischen Alternativen (GEMÜNDEN, 1988, S. 146).

Für die MDA muss die **Unabhängigkeit** der Kennzahlen gewährleistet sein. Bei Input-Variablen mit einer hohen Korrelation wird jeweils nur eine Variable verwendet. Die Korrelation zwischen den Kennzahlen kann dazu führen, dass die relative Bedeutung der Kennzahlen für die Klassifikation verzerrt wird. Der Grund liegt darin, dass sich positiv hoch korrelierte Kennzahlen ihren Beitrag zur Klassifikation teilen müssen und daher entsprechend niedrige Gewichte, also die Diskriminanzkoeffizienten, erhalten. Hoch negativ korrelierte Kennzahlen können in die Diskriminanzanalyse mit höheren

Gewichten eingehen und zwar mit negativen und positiven Vorzeichen, so dass die Diskriminanzwirkung sich teilweise wieder ausgleicht. Aus diesem Grund werden die Input-Variablen auf Korrelationen überprüft. Es werden nur schwach korrelierende Variablen als Input-Variablen verwendet.

Die **Trennfähigkeit** der einzelnen Kennzahlen wird anhand eines einfachen Mittelwertvergleichs vorgenommen (BURGER, 1995, S.289). Beispielsweise weist die Kennzahl "Zinsen" keine signifikanten Unterschiede bei den Mittelwerten für die beiden Klassen auf und wird aus diesem Grund bei der MDA aussortiert. Diese Kennzahl ist alleine nicht in der Lage, eine Trennung zwischen *finanziell gesund* und *finanziell gefährdet* vorzunehmen. Da diese Kennzahl bei der Klassifizierung mit dem NN nicht aussortiert worden ist, hat sie aber eine Bedeutung für die Wechselwirkungen mit anderen Kennzahlen und kann hierdurch einen Erklärungsbeitrag liefern.

Durch die Voraussetzungsbedingungen der MDA wird der Input-Kennzahlen-Katalog teilweise geändert und den statistischen Voraussetzungen angepasst. Dieser Input-Kennzahlen-Katalog, der zur Anwendung kommt, berücksichtigt mehr die statistischen Voraussetzungen als die fachlichen Gründe. Insgesamt werden nur 15 Variablen verwendet. Hierdurch gehen wertvolle Informationen über die Wechselwirkungen von Kennzahlen verloren.

Ausreißer

Zusätzlich zu den statistischen Anwendungsvoraussetzungen bestehen weitere Probleme bei der Anwendung der MDA. Das *Ausreißerproblem* der MDA, dass im Vergleich zum NN erheblich größere Auswirkungen hat, deutet auf eine schlechtere Klassifizierungsgüte der MDA hin (BURGER, 1995, S. 280). Unter "Ausreißer" versteht man extrem hohe und extrem niedrige Werte, wie beispielsweise bei der Kennzahl Nettoinvestition. Die MDA weist somit eine geringere Robustheit als die NN auf.

Insbesondere können durch diese Extremwerte Abweichungen zur Normalverteilung auftreten. Unterschiedliche Kennzahlenwerte können bei den zu klassifizierenden Unternehmen durch Ausreißer verschleiert werden. Die diskriminatorische Wirkung kann durch Ausreißer beeinträchtigt, verdeckt oder verfälscht werden. Bei der Bildung der Diskriminanzfunktion geht der vollständige Wert der Kennzahl in die Diskriminanzfunktion ein. Im Gegensatz hierzu werden bei dem NN die Extremwerte über die sigmoide Ausgabefunktionen geglättet. Hierdurch geht der Extremwert nicht mit seinem vollständigen absoluten Wert bei der Bildung des NN mit ein.

Bei der Bildung von Diskriminanzfunktionen muss auf Datensätze, die Extremwerte beinhalten, verzichtet werden. Für die MDA verbleiben somit 12 Input-Variablen aus

dem Gesamtkatalog übrig. Der zusätzliche Informationsgehalt der restlichen 14 Variablen geht verloren.

Folgende Kennzahlen bleiben bei der Anwendung für die MDA übrig:

TAB. 24: INPUT-VARIABLEN FÜR MDA

Input-Variablen für die MDA
Gesamtkapitalrentabilität (K 5)
Nettoinvestitionsquote (K 8)
Durchschnittliche Nettoinvestition (K 9)
Umsatzwachstum (K 10)
Entwicklung Fremdkapital (K 11)
Dyn. Verschuldungsgrad (K 14)
Anlagenintensität (K 17)
Fremdkapitalanteil (K 18)
Liquidität 3. Grades (K 19)
Unternehmensertrag zu Vermögen (K 21)
LF (K 25)
Abnutzungsgrad der Maschinen (K 26)

Quelle: Eigene Berechnungen

Linearität

Ein weiteres Problem bei der MDA ist die *Linearität* der Input-Variablen zu den Output-Variablen und der Input-Variablen untereinander. Die MDA kann nur lineare Beziehungen der Variablen berücksichtigen, aber in der Praxis liegen viele nicht lineare Beziehungen vor. Zur besseren Beurteilung der finanziellen Lage der Unternehmen werden unter anderem die Input-Variablen Eigenkapital-, Gesamtkapitalrentabilität, Zinsen, Fremdkapitalanteil und Entwicklung des Fremdkapitals verwendet. Die theoretischen Zusammenhänge dieser Kennzahlen sind nicht linear (vgl. Kapitel 4.1.4). Das NN ist in der Lage, diese Nichtlinearität abzubilden. Das kann zur einer besseren Klassifizierungsgüte führen.

5.2.2 Mögliche Konsequenz für die Praxis

Für den praktischen Einsatz von Klassifizierungsinstrumenten sind nicht nur rein zahlenmäßig fassbare Ergebnisse von Bedeutung, sondern auch eine Reihe von

anderen Faktoren. Einer dieser Faktoren ist der Aufwand im Verhältnis zum Nutzen. Dieser spiegelt sich in den Ergebnissen der verwendeten Methoden wieder, kann aber im Rahmen dieser Arbeit nicht quantifiziert werden.

Der Aufwand wird unterteilt in:

- Personeller Aufwand
- Technischer Aufwand

Personeller Aufwand

Im Vorfeld aller Entwicklungsarbeiten muss für die Datenaufbereitung, die Definition und die Berechnung der Kennzahlen ein nicht erheblicher Aufwand in Kauf genommen werden. Dies betrifft in gleicher Weise alle Verfahren und reduziert sich nach der erstmaligen Implementierung des Systems auf die regelmäßige Überprüfung der Klassifizierungen und eventuellen Aktualisierungen mit neuen Daten.

Die lineare MDA ist mittlerweile ein bewährtes Verfahren, das keine besonderen Probleme mehr bereitet. In der Literatur vielfach untersucht und gewürdigt, sind hinsichtlich der Ermittlung einer Diskriminanzfunktion keine bahnbrechenden Neuerungen mehr zu erwarten. Aufwendig gestaltet sind hier die Vortests zur Überprüfung der methodischen Anwendungsvoraussetzungen. Da sich in den meisten Untersuchungen bisher erwiesen hat, dass die Voraussetzungen häufig nicht erfüllt sind und die Diskriminanzfunktion trotzdem zufriedenstellend trennfähig ist, könnte in künftigen Arbeiten zu mindest auf die Untersuchung der Normalverteilung verzichtet werden. Dann würde sich der häufig zitierte Arbeitsaufwand der MDA erheblich reduzieren lassen. Bereits ein mathematisch interessierter PC-Anwender kann sich nach kurzer Einarbeitungszeit in ein Statistikprogramm an die Arbeit machen, eine Diskriminanzanalyse zu entwickeln.

Bei den NN ist die derzeitige Situation anders, weil bisher nur wenige gesicherte Erkenntnisse darüber vorliegen, welche Parametereinstellung von Nöten sind, und nach welchem Verfahren die Anpassung dieser Einstellung erfolgt. Der langwierige Entwicklungsprozess sorgt somit dafür, dass der Aufwand im Vergleich zur MDA gegenwärtig höher ist. Dazu kommt, dass es beim heutigen Stand der Technik einem nicht mit NN vertrauten Anwender kaum möglich ist, zu brauchbaren Ergebnissen zu gelangen.

Technischer Aufwand

Das NN erfordert einen leistungsfähigeren PC für das Trainieren des Netzes. Aufgrund der heutigen Entwicklung der PC befinden sich die neueren auf dem technischen Stand, dass NN ohne längere Lernzeiten trainiert werden können. Somit entfällt das

früher häufig vorgebrachte Argument gegen NN, dass diese eine technische Ausstattung der Rechner voraussetzen, die an den meisten PC-Arbeitsplätzen nicht vorhanden sind.

Nachvollziehbarkeit von MDA und NN

Ein weiteres Kriterium für die Güte des Modells ist neben der Klassifizierungsleistung die Transparenz und Nachvollziehbarkeit (BLOCHWITZ UND EIGERMANN, 2000, S.246). Im einzelnen bedeutet dies, dass der Einfluss aller oder zumindest der wichtigsten Informationen durch das Modell aufgezeigt und von einem Externen verstanden werden kann.

Sowohl bei der MDA als auch bei dem NN handelt es sich um einen Black-Box Ansatz. Jedem Unternehmen wird ein Gefährdungsgrad zugeordnet, ohne dass dies inhaltlich für einen Externen nachvollziehbar ist. Die Akzeptanz eines NN ließe sich erheblich steigern, wenn eine Erklärungskomponente in ein Netz integriert werden könnte. Für das MLP bietet sich die Sensitivitätsanalyse als Erklärungskomponente an. Grundgedanke des Verfahrens ist es, den Output bezüglich jeder einzelnen Kennzahl zu untersuchen (KERLING und PODDIG, 1994, S.482f.). Die Sensitivitätsanalyse stellt aber nur einen Ansatz einer Erklärungskomponente dar, weil die Interpretation nicht auf Ursachen-Hypothesen basiert.

5.3 Fazit

Die Klassifizierungsergebnisse haben gezeigt, dass die Verwendung von NN und FS zu keinem Quantensprung bezüglich der Klassifizierungsgüte führt. Dennoch ist die Verbesserung der Klassifizierungsgüte durch das FNN-Modell als Fortschritt zu werten.

Aus den Erfahrungen dieses Modells sind zwei Ansätze zur Verbesserung der Klassifizierungsergebnisse erkennbar. Hierbei handelt es sich einmal um die Erweiterung der verfügbaren Daten und zum anderen um die Weiterentwicklung der Methoden.

Trotz des umfangreichen Datenmaterials sind weitere Verbesserungen hinsichtlich der Datenverfügbarkeit wünschenswert. Gemäß einer qualitativen Jahresabschlussanalyse können Daten außerhalb der Bilanz und der Gewinn-und-Verlust Rechnung mit einbezogen werden. Diese liegen in dem neuen betriebswirtschaftlichen BML-Jahresabschluss vor und können für weitere Untersuchungen verwendet werden.

Für gezielte Fragestellungen, wie beispielsweise die der finanziellen Situation eines Unternehmens nach einer getätigten Investition, muss ein Modell mit den hierfür geeigneten Daten entwickelt werden. Für diese Fragestellungen sollten bei der

Modellentwicklung nur Datensätze von Unternehmen mit getätigten Investitionen verwendet werden.

Neben der Erweiterung der Datenbasis bieten auch die Methodenerweiterungen Verbesserungspotentiale. Der Forschungsbereich der NN befindet sich zwar in den letzten Jahren in einer Stagnationsphase, aber gerade die Kombination mit anderen Methoden wie dem Fuzzy System, genetischen Algorithmen und anderen Instrumenten bieten vielversprechende Verbesserungspotentiale.

Die Kombination von NN und FS brachte in den letzten Jahren eine Vielzahl an Weiterentwicklungen. Das Einsatzgebiet beschränkt sich nicht nur auf das im Modell beschriebene Verfahren. Beispielsweise ermitteln NN auch aus einer Datenbank die Zugehörigkeitsfunktion zur Modellierung der linguistischen Terme oder die linguistischen Kontrollregeln. Diese Aufgaben könnten die NN mit Hilfe eines Cluster-Verfahrens, das meist aus selbstorganisierenden Karten oder ähnlichen neuronalen Architekturen besteht, realisieren. Die benötigten Zugehörigkeitsfunktionen müssten in diesem Fall gesondert definiert werden. Des Weiteren können die NN Gewichtungsfaktoren für die Fuzzy Regeln ermitteln.

6 Zusammenfassung

Die wachsende Verschuldung der Unternehmen und die größer werdenden Unsicherheiten in der landwirtschaftlichen Produktion führen dazu, dass Früherkennungsinstrumente für finanzielle Fehlentwicklungen an Bedeutung gewinnen.

Die Grundlage vieler dieser Früherkennungsinstrumente sind Buchführungsdaten landwirtschaftlicher Unternehmen. Die Jahresabschlussanalyse ist ein anerkanntes Verfahren zur Beurteilung der finanziellen Situation eines Unternehmens. Zwar können mit den Buchführungsdaten nicht alle betriebswirtschaftlichen Fragestellungen beantwortet werden, aber dennoch handelt es sich hierbei um die bestmögliche Datengrundlage, die im größeren Umfang zur Verfügung gestellt werden kann.

Früher durchgeführte traditionelle Jahresabschlussanalysen wie der Kennzahlenvergleich sind für die Ermittlung der finanziellen Stabilität der Unternehmen nicht ausreichend. Der Informationsgehalt einzelner Kennzahlen ist begrenzt, wenn die Wechselwirkungen zu den anderen Kennzahlen nicht bekannt sind. Die notwendige Theorie der Jahresabschlussanalysen zur Bildung einer Gesamtaussage aus den einzelnen Kennzahlen liegt nicht vor.

Wegen der Schwächen der traditionellen Jahresabschlussanalysen werden zunehmend empirisch-statistische Methoden eingesetzt. Da es sich bei diesem Verfahren um Black-Box-Ansätze handelt, ist keine geschlossene Theorie der Jahresabschlussanalyse für die Modellentwicklung notwendig. Diese Methoden erheben nicht den Anspruch, die Ursachen-Wirkungs-Zusammenhänge aufzudecken, sondern dienen als Klassifizierungsverfahren.

In den 70er Jahren etablierten sich zuerst Diskriminanzanalysen als empirisch-statistische Klassifizierungsinstrumente. Aufgrund ihrer Anwendungsvoraussetzungen, die nicht vollständig erfüllbar sind, werden sie mehr und mehr durch Neuronale Netze (NN) verdrängt. Für die NN existieren diese Anwendungsvoraussetzungen nicht. Des weiteren weisen NN gegenüber den Diskriminanzanalysen folgende Vorteile auf:

- Lernfähigkeit
- Generalisierbarkeit
- Fehlertoleranz

Bei den NN handelt es sich um Instrumente der Künstlichen Intelligenz. Die mathematische Theorie der NN ist entwickelt worden, um komplexe nichtlineare Systeme zu beschreiben. Die Anwendungsgebiete der NN liegen in vielen verschiedenen Themenbereichen. Sie fanden auch Zugang in die Ökonomie und Ökonometrie. NN sind Systeme, die einige im Gehirn erkannten und vermuteten

Organisationsprinzipien ausnutzen. Sie bestehen aus einer Vielzahl an Neuronen, die über gewichtete Verbindungen Nachrichten austauschen.

NN sind in der Lage, aus Beispieldaten zu lernen. Ihr Einsatz ist immer dann vorteilhaft, wenn kein mathematisches Modell vorliegt oder dessen Umsetzung aufgrund hoher Kosten vermieden werden soll. NN können strukturell vollständig unbekannte Systeme beherrschen, soweit deren Eingabe- und Ausgabeverhalten bekannt sind. Deshalb werden die NN für den Teil des Modells verwendet, für den kein Wissen über die Zusammenhänge der Ausgangsdaten vorliegt.

Im Gegensatz hierzu benötigen Fuzzy Systeme (FS) Wissen in Form linguistischer Regeln. Hierbei handelt es sich um vages Wissen. FS benötigen keine exakten Regeln und Theorien. Durch die Verwendung nicht perfekter Informationen lässt sich gezielt der Vorteil einer damit verbundenen Komplexreduktion gegenüber anderen Systemen ausnutzen. Der Einsatz von FS verfolgt genau diese Strategie.

Das Klassifizierungsmodell FNN wird in die Teilbereiche NN und FS unterteilt. Gerade die Kombination von NN mit FS kann eine zusätzliche Verbesserung der Klassifizierungsergebnisse erbringen. Diese beiden Methoden weisen unterschiedliche Vor- und Nachteile, die sich ergänzen, auf.

Die Klassifizierungsinstrumente ordnen die Unternehmen den jeweiligen Klasse zu. Bei den Klassen handelt es sich um die Merkmalsausprägungen "*finanziell gefährdet*" und "*finanziell gesund*" hinsichtlich des finanziellen Zustandes eines Unternehmens. Der finanzielle Zustand ist aber empirisch nicht eindeutig erfassbar. Dieser kann aber mit Hilfe von Kennzahlen beschrieben werden. Folgende drei Kennzahlen werden hierfür verwendet:

- Gesamtkapitalrentabilität
- Fremdkapitalanteil
- dynamischer Verschuldungsgrad

Die Ereignisbildung dieser drei Kennzahlen des FNN-Modells erfolgt durch ein FS. Das grobe Wissen der Fuzzy-Regeln über den finanziellen Zustand der Unternehmen kann zur Verbesserung der Klassifizierungsleistung im Modell mitberücksichtigt werden. Durch die Fuzzy-Regeln werden die groben Beziehungen der drei Kennzahlen für das Modell beschrieben. Dieses vorhandene Wissen über die Beziehung der Kennzahlen wird im Modell zur Klassifizierung der Unternehmen genutzt und braucht nicht über ein NN gelernt werden.

Für das FNN-Modell sind drei verschiedene NN entwickelt worden. Für die beschreibenden Variablen des Zustandes der finanziellen Gefährdung

Gesamtkapitalrentabilität, Fremdkapitalanteil und dynamischer Verschuldungsgrad liegt jeweils ein eigenes NN vor.

Als Netztyp des NN ist das Multilayer Perceptron (MLP) mit dem Backpropagation-Algorithmus eingesetzt worden. Dieses NN ist aufgrund seiner guten Eignung und bisherigen Erfolge in der Klassifizierung verwendet worden. Das MLP besteht aus einem Input-Layer, einem Hidden-Layer und einem Output-Layer.

Die Input-Layer weisen eine unterschiedliche Anzahl von Input-Variablen auf. Die Anzahl ist davon abhängig, ob die jeweiligen Input-Variablen zur Verbesserung des Klassifizierungsergebnisses führen. Die verwendeten Input-Variablen sind mit Hilfe des trail-and-errors Verfahren ermittelt worden. Die Vorgehensweise der Aussortierung der Kennzahlen erfolgt mit Hilfe des Koordinatenverfahrens.

Die Neuronenanzahl des Hidden-Layers wird wiederum mit Hilfe des trail-and-errors Verfahren ermittelt. Die Variablenanzahl im Output-Layer ist allerdings von vornherein festgelegt. Aufgrund der binären Klassifizierungsfähigkeit eines Neurons können keine drei Klassenausprägungen mit Hilfe eines Neurons ermittelt werden. Deshalb müssen drei Output-Neuronen für die drei möglichen Merkmalsausprägungen jeder Output-Variablen verwendet werden.

Die drei Output-Kennzahlen werden über ein FS zu einer Merkmalsausprägung eines Ereignisses verdichtet. Hierbei handelt es sich um die Merkmalsausprägungen "finanziell gefährdet" und "finanziell gesund" des finanziellen Zustandes eines landwirtschaftlichen Unternehmens.

Bei der Verwendung des FS müssen die Output-Variablen zuerst fuzzifiziert werden. Die Werte der jeweiligen Variable werden durch Zugehörigkeitsfunktionen den Zugehörigkeitswerten der jeweiligen Klasse zugeordnet. Bei den Zugehörigkeitsfunktionen handelt es sich um s-förmige Funktionen, weil diese die nicht-technischen Anwendungsproblemen am besten beschreiben. Es werden für jede Output-Variable die drei linguistischen Fragmente unterdurchschnittlich, durchschnittlich und überdurchschnittlich verwendet.

Die Fuzzy-Inferenzregeln werden anhand des Wissens über die Zusammenhänge der Kennzahlen ermittelt. Hier sind vor allem die Wechselwirkungen zwischen der Rentabilität und Stabilität, die durch die Kennzahlen Gesamtkapitalrentabilität und Fremdkapitalanteil repräsentiert werden, näher analysiert worden. Für die Berechnung der Fuzzy-Regeln wird der Fuzzy-Mengen-Operator "Fuzzy-und" verwendet. Im letzten Schritt werden die Konklusionen aller Regeln zusammengefasst, weil meistens mehr als eine Regel zutrifft. Hierfür wird das *Max-Prod-Inferenz-Verfahren* verwendet.

Das FS ermittelt die Zugehörigkeitswerte für die vorliegenden Daten aus dem Wirtschaftsjahr 1996/97 und für die Werte, die durch das NN klassifiziert wurden. Anschließend erfolgt ein Vergleich zwischen den beiden ermittelten Zugehörigkeitswerten für jedes Unternehmen. Der Zugehörigkeitswert gibt zusätzlich den Grad der Zugehörigkeit zu der jeweiligen Klasse an. Hierdurch wird der Grad der finanziellen Gefährdung der Unternehmen ermittelt.

Bei der Ursachenforschung, wodurch Fehlklassifizierungen entstehen können, stellt sich heraus, dass durch das vorliegende, auf Buchführungsdaten beruhende Datenmaterial die Prämisse der Zeitstabilität nicht eingehalten wird und Buchführungsdaten nicht alle notwendigen Informationen zur Beurteilung der finanziellen Situation liefern können.

Anhand der Ergebnisse des FNN-Modells kann nicht gefolgert werden, ob dieses Verfahren bessere Ergebnisse liefert als bisherige empirisch-statistische Klassifizierungsinstrumente. Deshalb werden die Ergebnisse, die mit dem FNN-Modell ermittelt worden sind, mit den Ergebnissen einer MDA verglichen. Die MDA wurde als Vergleichsinstrument gewählt, weil dieses Instrument bisher erfolgreich für ähnliche Aufgabenstellungen eingesetzt worden ist. Bei diesem Vergleich kann festgestellt werden, dass das FNN-Modell bessere Klassifizierungsergebnisse liefert als die MDA.

Die Aufteilung des Modells in einen Klassifizierungsteil und die anschließenden Zusammenführung der drei Kennzahlen zu einem Zustand hat den Vorteil, dass das vorhandene vage Wissen über das FS mitberücksichtigt werden kann. Bei "finanziell gefährdeten" Unternehmen liegen unterschiedliche Gründe für ihre finanzielle Lage vor. Dementsprechend weisen diese Unternehmen unterschiedliche Kennzahlen-muster auf. Bei der Klassifizierung von unterschiedlichen Kennzahlenmustern für ein Ereignis sinkt die Klassifizierungsgenauigkeit. Durch die Aufteilung des FNN-Modells in ein Klassifizierungselement und einem FS werden nur die jeweiligen Output-Variablen klassifiziert.

Literaturverzeichnis

ALTMAN, E. I. (1967): The Prediction of Corporate Bankruptcy: A Diskriminanz Analysis, Los Angeles.

ALTMAN, E. I. UND A. SAUNDERS (1998): Credit risk measurement: Developments over the last 20 years, Journal of Banking and Finance 21 (1998): 1721 - 1742.

ALTROCK, VON, C. (1997): Fuzzy Logic and NeuroFuzzy in Business and Finance, Upper Saddle River, NJ.

BALLWIESER, W. (1987): Die Analyse von Jahresabschlüssen nach neuem Recht, WPg, S. 57-68.

BARRY, P.J.; ELLINGER, P.N.; HOPKIN J.A. UND C.B. BAKER (2000): Financial Management in Agriculture, 6. Aufl., Danville, Illinois.

BAETGE, J. (1980): Früherkennung negativer Entwicklungen der zu prüfenden Unternehmungen mit Hilfe von Kennzahlen, WPg, S. 651-665.

BAETGE, J. (1980): Bilanzen, 2. Aufl., Düsseldorf.

BAETGE, J.: (1994): Rating von Unternehmen anhand von Bilanzen, Die Wirtschaftsprüfung, 47. Jg., 1994, S. 1-10.

BAETGE, J. UND A. JERSCHENSKY (1996): Beurteilung der wirtschaftlichen Lage von Unternehmen mit Hilfe von modernen Verfahren der Jahresabschlussanalyse, Der Betrieb, 49. Jg., Heft 32, S.1581-1591.

BEAVER, W. (1965): Financial Ratios as Predictors of Failure, Chicago.

BERG, E. UND F. KUHLMANN (1993): Systemanalyse und Simulation: für Agrarwissenschaftler und Biologen, Stuttgart.

BERG, E.; THOER, K. UND G. STEFFEN (1988): Konzeption und Entwicklung bioökonomischer Modelle, Agrarwirtschaft, Jg. 37, H. 1, S. 1-10.

BIETHAHN, J.; HÖRNERLOH, A.; KUHL, J. UND V. NNSSEN (1997): Fuzzy Set-Theorie in betriebswirtschaftlichen Anwendungen, München.

BLACK, M. (1937): Vagueness: An exercise in logical analysis, Philosophy of Science 4. S. 427 - 455.

BLOCHWITZ, S. UND J. EIGERMANN (2000): Krisendiagnose durch quantitatives Credit-Rating mit Fuzzy-Regeln, in HAUSSCHILDT, J. UND J. LEKER (2000): Krisendiagnose durch Bilanzanalyse, 2. Aufl., Köln.

BMELF (1999): Agrarbericht der Bundesregierung 1999.

BODMER, U. UND A. HEIßENHUBER (1993): Rechnungswesen in der Landwirtschaft, Stuttgart.

BODMER, U. (2001): Ansätze zur verbesserten Erkennung von Unternehmenskrisen aus Buchführungsdaten, Berichte über Landwirtschaft, Band 79(1), S. 5-18, Münster-Hiltrup.

BÖHME, G. (1993): Fuzzy-Logik: Eine Einführung in algebraische und logische Grundlagen, Heidelberg.

BOSSEL, H. (1994): Modellbildung und Simulation, 2. Aufl., Wiesbaden.

BOTHE, H. H. (1998): Neuro-Fuzzy-Methoden: Einführung in Theorie und Anwendungen, Heidelberg.

BRANDES, W. und E. WOERMANN (1971): Landwirtschaftliche Betriebslehre, Band 2, Hamburg.

BRANDES, W. UND M. ODENING (1992): Investition, Finanzierung und Wachstum in der Landwirtschaft, Stuttgart.

BRAUN, S. (1994): Neuronale Netze in der Aktienkursprognose: Neue Möglichkeiten der Modellentwicklung, in REHKUGLER, H. UND H.G. ZIMMERMANN (1994): Neuronale Netze in der Ökonomie, München.

BÜHL, A. UND ZÖFEL, P. (1996): SPSS für Windows: Praxisorientierte Einführung in die moderne Datenanalyse, Bonn.

BURGER, A. (1995): Jahresabschlussanalyse, München.

BURMESTER, C. (1996): Existenzsicherung von Unternehmen bei unsicheren Erwartungen: Literaturanalyse sowie Entwicklung und Anwendung eines Simulationsmodells zur Formulierung flexibler Investitions- und Finanzierungsstrategien, Berlin.

COENENBERG, A.G. (1988): Jahresabschluß und Jahresabschlussanalyse, Landsberg am Lech.

DEUTSCHER BAUERNVERBAND (1999): Situationsbericht 2000, Bonn.

DESAI, V. S.; CROOK, J. N. UND G. A. OVERSTREET (1996): A comparison of neural networks and linear scoring models in credit union environment, European Journal of Operational Research 95 (1996), S. 24 - 37.

DINKELBACH, W. (1973): Modell - ein isomorphes Abbild der Wirklichkeit? in: GROCHLA, E. UND N. SZYPERSKY (1973): Modell- und computergestützte Unternehmensplanung, Wiesbaden.

DLG-Arbeitsunterlagen B/89 (1989): Pflichtheft für die integrierte Betriebsrechnung in der Landwirtschaft, Frankfurt.

DLG-Arbeiten (1997): Effiziente Jahresabschlussanalyse: Neue einheitliche Erfolgskennzahlen für landwirtschaftliche Betriebe aller Rechtsformen, Band 194, Frankfurt am Main.

DOWNEY, W.D. UND ERICKSON, S.P. (1987): Agribusiness Management, 2.Aufl., New York.

DREYFUS, H.L. UND S.E. DREYFUS (1987): Künstliche Intelligenz, von den Grenzen der Denkmaschinen und dem Wert der Intuition, Hamburg.

ERXLEBEN, K. U.A. (1992): Klassifikation von Unternehmen - ein Vergleich von Neuronalen Netzen und Diskriminanzanalyse, Zeitschrift für Betriebswirtschaft, S. 1237-1262).

FALKENBURG, B. (1997): Modelldenken in den Wissenschaften, Hamburg.

FEIDICKER, M. (1992): Kreditwürdigkeitsprüfung. Entwicklung eines Bonitätsindikators, Düsseldorf.

FELSCHER, K. (1988): Krisenursachen und rechnungsgestützte Früherkennung, Reihe Wirtschaftswissenschaften, Band 40, Pfaffenweiler.

GALINDO, J. UND P. TAMAYO (2000): Credit risk assessment using statistical and machine Learning: Basic methodology and risk modelling applications. Computational Economics 15: S. 107-143.

GEMÜNDEN, H. G. (1988): Defizite der empirischen Insolvenzforschung, in Hausschildt, J. (1988): Krisendiagnose durch Bilanzanalyse, Köln.

GOLDBERG, D. (1989): Genetic Algorithms in Search, Optimization, and Machine Learning, Reading, MA.

GOTTSCHLICH, W. (1995): Empirische Identifikation von typischen Schwachstellenprofilen landwirtschaftlicher Unternehmen, Diss., Bonn.

GRÄFER, H. (1990): Bilanzanalyse, 5. Aufl., Berlin.

GRAVES, O.F.; BARNEY, D.K. UND J.D. JOHNSON (1999): The farmers home administration and farm debt failure prediction, Journal of Accounting and Public Policy, 18, Nr. 2, S. 99-139.

GUTENBERG, E. (1973): Grundlagen der Betriebswirtschaftslehre, Bd. II: Der Absatz, 14. Aufl., Berlin.

HAFNER, T. (1997): Früherkennung von Unternehmenskrisen mit mathematisch-statistischen Methoden und Methoden der künstlichen Intelligenz. Eine vergleichende empirische Untersuchung dargestellt am Beispiel des Unternehmensbereichs Produktion, Frankfurt am Main.

HARTUNG, J. (1998): Statistik: Lehr- und Handbuch der angewandten Statistik, 11. Aufl., München.

HAUSSCHILDT, J. (1988): Krisendiagnose durch Bilanzanalyse, Köln.

HAUSSCHILDT, J. (1996): Erfolgs-, Finanz-, und Bilanzanalyse, Köln.

HAUSSCHILDT, J. UND J. LEKER (2000): Krisendiagnose durch Bilanzanalyse, 2. Aufl., Köln.

HAWLEY, D.D.; JOHNSON, J.D. UND D. RAINA (1994): Artificial Neural Systems: A new tool for Financial Decision Making, in TRIPPI, R.R. UND E. TURBAN (1994): Neural Networks in Finance and Investing, 2.Aufl., Chicago.

HEBB, D.O. (1949): The Organization of Behavior, S. 60 - 78, New York: auch in ANDERSON, J.A. und E. ROSENFELD (1988): Neurocomputing: Foundations of Research, Kapitel 4, S. 45 - 56.

HENO, R. (1983): Kreditwürdigkeitsprüfung mit Hilfe von Verfahren der Mustererkennung, Stuttgart.

HORST, R. (1979): Nichtlineare Optimierung, München.

JENßEN, A. (1999): Unscharfe Zahlen in der Finanzwirtschaft: Fuzzy Sets zur Erfassung von Unsicherheit, Göttingen.

KASTNER, W. (1991): Bilanzidentität und mehrjährige Betriebsergebnisse. In: Bayerisches Landwirtschaftliches Jahrbuch, 68. Jahrgang, S. 787ff., Wolnzach.

KASTENS, T.L. UND A.M. FEATHERSTONE (1999): Financial Update, Risk & Profit, and Outlook. Presented at: Risk and Profit 1999 Conference Holiday Inn Holidome, Manhattan, Kansas.

KAPPLER, E. (1974): Bilanzanalyse und Bilanzkritik, in: GROCHLA, E. UND W. WITTMANN (Hrsg.) Handwörterbuch der Betriebswirtschaft, 4. Aufl., Bd.1, Stuttgart.

KERLING, M. UND TH. PODDIG (1994): Klassifikation von Unternehmen mittels KNN, in: REHKUGLER UND ZIMMERMANN (1994): Neuronale Netze in der Ökonomie, München.

KERTH, A. UND J. WOLF (1986): Bilanzanalyse und Bilanzpolitik, München.

KIMME, O. (1981): Betriebs- und Betriebszweigvergleich in der Landwirtschaft, Schriftenreihe des HLBS, Heft 98, Bonn.

KINNEBROCK, W. (1994): Neuronale Netze, München.

KÖCKLER, D. (1999): Landwirtschaftliche Unternehmensberatung: Potentialanalyse und Neuausrichtung der betriebswirtschaftlichen Beratung am Beispiel der Landwirtschaftskammer Rheinland, Frankfurt am Main.

KÖHLE, M. (1990): Neuronale Netze, in SCHAUER, H. (1990): Neuronale Netze, Wien.

KOHLEN, T. (1986): Learning Vector Quantization for Pattern Recognition, Tech. Rep-No. TKK-F-A601, Helsinki.

KOSIOL, E. (1964): Betriebswirtschaftslehre und Unternehmensforschung, Zeitschrift für Betriebswirtschaft, 34. Jahrgang.

KOSIOL, E. (1976): Pagatorische Bilanz, Berlin.

KRATZER, K P. (1993): Neuronale Netze: Grundlagen und Anwendungen, 2. Auflage, München.

KRUMNOV. J. (1985): Bilanzanalyse auf der Basis der neuen Rechnungslegungsvorschriften, Zeitschrift für betriebswirtschaftliche Forschung, S. 117-128.

KRAUSE, C. (1993): Kreditwürdigkeitsprüfung mit Neuronalen Netzen, Düsseldorf.

KRUSE, R.; GEBHARDT, J. UND F. KLAWONN (1993): Fuzzy Systeme, Stuttgart.

KUHLMANN, F. UND P. WAGNER (1986): Zur Nutzung der Informationselektronik im landwirtschaftlichen Betrieb, Berichte über die Landwirtschaft, Band 64, H. 3, S. 408-440.

KÜTING, K. UND C.-P. WEBER (1994): Die Bilanzanalyse, 2. Aufl., Stuttgart.

LACHNIT, L. (1976): Zur Weiterentwicklung betriebswirtschaftlicher Kennzahlensystem, Zeitschrift für betriebswirtschaftliche Forschung, 28. Jahrgang.

LAND-DATA (1999): Datendokumentation 1996 bis 1999 zum Situationsbericht des Deutschen Bauernverbandes, Visselhövede.

LEFFSON, U. (1977): Bilanzanalyse, Stuttgart.

LUKASIEWICZ, J. (1957): ARISTOTELE's syllogistic: From the standpoint of modern formal logic, Oxford.

MANTHEY, R.P. (1995): Der neue BML-Jahresabschluß - Grundlagen, Kurzdarstellung, Hintergründe -, Schriftenreihe des Hauptverbandes der landwirtschaftlichen Buchstellen und Sachverständigen, 2. Aufl., Sankt Augustin.

MÄRZ, T. (1983): Interdependenzen in einem Kennzahlensystem, München.

- MCCULLOCH, W.S. UND W. PITTS (1943): A logical calculus of the ideas immanent in nervous activity, Bulletin of Mathematical Biophysics 5: 115 - 133, auch in ANDERSON, J.A. und E. ROSENFELD (1988): Neurocomputing: Foundations of Research, Kap. 2, S. 18 - 28.
- MEIMBERG, P. (1966): Landwirtschaftliches Rechnungswesen: Einführung in Buchhaltung, Kostenrechnung, Kalkulation und Betriebsplanung, Stuttgart.
- MELICHAR, E. (1983): Farm wealth: origins, impact, and implications for public policy.
- MERTENS, P. (1977): Die Theorie der Mustererkennung in den Wirtschaftswissenschaften, ZfbF, 29. Jg., S.777-794.
- MICHALEWICZ, Z. (1992): Genetic Algorithms + Data Structures = Evolution Programs, Berlin.
- NAUCK, D. UND R. KRUSE: (1997): Fuzzy-Systeme und Soft Computing, in BIETHAHN, J. (1997): Fuzzy Set-Theorien in betriebswirtschaftlichen Anwendungen, München.
- NAUCK, D.; KLAWONN, F. UND R. KRUSE (1994): Neuronale Netze und Fuzzy-Systeme: Grundlagen des Konnektionismus, Neuronaler Fuzzy-Systeme und der Kopplung mit wissensbasierten Methoden, Wiesbaden.
- NG, K. UND B. ABRAMSON (1990): Uncertainty Management in Expert Systems, IEEE Expert, S.29 - 47.
- NIEHAUS, H.-J. (1987): Früherkennung von Unternehmenskrisen - Die statistische Jahresabschlußanalyse als Instrument der Abschlussprüfung, Düsseldorf.
- ODENING, M. UND W. BOCKELMANN (2000): Agrarmanagement, Stuttgart.
- PEDRYCZ, W. (1989): Fuzzy control and fuzzy systems, Taunton.
- PODDIG, T. (1992): Künstliche Intelligenz und Entscheidungstheorie, Wiesbaden.
- PYTLIK, M. (1995): Diskriminanzanalyse und Künstliche Neuronale Netze zur Klassifizierung von Jahresabschlüssen. Ein empirischer Vergleich, Frankfurt am Main
- QUIRING, A. (1996): Die Buchführung als Hilfsmittel der Betriebsführung in der Landwirtschaft, Diplomarbeit, Institut für landwirtschaftliche Betriebslehre, Bonn.
- RADTKE, R. (1993): Rechnungswesen, Buchführung und Bilanz in der Land und Forstwirtschaft, 3. Aufl., Wiesbaden.
- REHKUGLER, H. UND TH. PODDIG (1993): Bilanzanalyse, München.
- REICHMANN, T. (1990): Controlling mit Kennzahlen: Grundlagen einer systemgestützten Controlling-Konzeption, 2. Aufl., München.

- RIEBELL, C. (1992): Die Praxis der Bilanzauswertung, 5. Aufl., Stuttgart.
- ROMMELFANGER, H. (1991): Fuzzy control und Fuzzy-logic-basierte Expertensysteme, Frankfurt am Main.
- ROMMELFANGER, H. (1988): Fuzzy Decision Support-Systeme – Entscheiden bei Unschärfe, Heidelberg.
- ROJAS, R. (1996): Theorie der neuronalen Netze: eine systematische Einführung, Berlin.
- RÖSLER, J. (1986): Bilanzanalyse durch den Vergleich von projizierten und realisierten Jahresabschlüssen: Eine empirische Untersuchung über Projektionstechniken in der Bilanzauswertung und ihre Einsatzmöglichkeiten, Kiel.
- RUMELHART, D.E.; HINTON, G.E. UND R.J. WILLIAMS (1986): Learning internal representations by error propagation, in RUMELHART, D.E. UND J.L. MCCLELLAND (1986): Parallel Distributed Processing: Explorations in the Microstructure of Cognition. Vol. 1, S.318 - 362, Cambridge, MA.
- RUMELHART, D.E. UND J.L. MCCLELLAND (1986): Parallel Distributed Processing: Exploration in the Microstructure of Cognition. Vol. 1: Foundations, Cambridge MA.
- SCHEFFELS, R. (1996): Kennzahlengestützte Analyse der Vermögens-, Finanz- und Ertragslage im Rahmen der Jahresabschlussprüfung – Entwicklung eines wissensbasierten Systems auf der Basis der Fuzzy-Logik, Wiesbaden.
- SCHERER, A. (1997): Neuronale Netze: Grundlagen und Anwendungen, Braunschweig.
- SCHEUERLEIN, A. (1997): Finanzmanagement für Landwirte: Beispiele, Anwendungen, Beurteilungen, Frankfurt am Main.
- SCHÖNEBURG, E.; HANSEN N. UND A. GAWELCZYK (1990): Neuronale Netzwerke, Haar bei München.
- SCHMAUNZ, F. (1995): Buchführung in der Landwirtschaft: Bilanz, Auswertung, Gewinnermittlung, München.
- SCHNEIDER, D. (1990): Investition, Finanzierung und Besteuerung, 6. Aufl., Wiesbaden.
- SCHULZE, H.-H. (1966): Zum Problem der Messung des wirtschaftlichen Handelns mit Hilfe der Bilanzanalyse, Berlin.
- SIENER, F. (1991): Der Cash-Flow als Instrument der Bilanzanalyse. Praktische Bedeutung für die Beurteilung von Einzel- und Konzernabschluß, Stuttgart.
- SPREMANN, K. (1996): Wirtschaft, Investition und Finanzierung, 5. Aufl., München.

SMITH, K. A. UND J. N. D. GUPTA (2000): Neural networks in business: techniques and applications for the operations researcher, Computers & operations research 27 (2000), S. 1023 - 1044

STAEHLE, W. (1973): Kennzahlensysteme als Instrument der Unternehmensforschung, in: Wirtschaftswissenschaftliches Studium.

STAEHLE, W. (1975): Das DuPont-System und verwandte Konzepte der Unternehmenskontrolle, in: BÖCKER, F. UND E. DICHTL (1975): Erfolgskontrolle in Marketing, S. 317 - 336, Berlin.

STEINHAUSER H.; LANGBEHN C. UND U. PETERS (1992): Einführung in die landwirtschaftliche Betriebslehre, Allgemeiner Teil, 5. Aufl., Stuttgart.

STEFFEN, G. UND D. BORN (1987): Betriebs- und Unternehmensführung in der Landwirtschaft, Stuttgart.

STOLTE, F. (1976): Theoretische und organisatorische Grundlagen eines computergestützten Abweichungskontrollsystems (CAS) im Rechnungswesen landwirtschaftlicher Unternehmen, Gießen.

STOLZKE, U.A. (1999): Neuronale Netzsimulatoren zur Prognose von Zeitreihen im Überblick, Zeitschrift für Agrarinformatik, Jg. 7 (1999), H. 2 (April, Juni), S. 46-48).

TERANO, T.; ASAI, K. UND M. SUGENO (1992): Fuzzy Systems Theory and Application, San Diego.

TRIPPI, R. R. UND E. TURBAN (1996): Neural Networks in Finance and Investing: Using Artificial Intelligence to Improve Real-World Performance, 2.Aufl., Chicago.

UTHOFF, C. (1997): Erfolgsoptimale Kreditwürdigkeitsprüfung auf der Basis von Jahresabschlüssen und Wirtschaftsauskünften mit künstlichen Neuronalen Netzen, Stuttgart.

WAGNER, P. (1992): Methodische Grundlagen und praktische Entwicklung eines Expertensystems für die Wirtschaftlichkeitsanalyse landwirtschaftlicher Betriebe, Agrarwirtschaft, Sonderheft.

WAN, L.-X. (1994): Adaptive Fuzzy Systems and Control: design and stability analysis, Englewood Cliffs.

WARREN, M. (1997): Financial Management for Farmers and Rural Managers, 4. Aufl., Oxford.

WEBER, H.K. (1974): Betriebliches Rechnungswesen, München.

WERBOS, P.J. (1974): Beyond regression: new tools for prediction and analysis in the behavioral sciences, Cambridge, MA. Auch in WERBOS, P.J. (1994): The roots of Backpropagation: From Ordered Derivatives to Neural Networks and Political Forecasting, Reading, MA.

WEST, D. (2000): Neural network credit scoring models, Computers & operations research, 27, (2000), S. 1131 - 1152.

WILBERT, R. (1995): Interpretation und Anwendung neuronaler Netze in den Wirtschaftswissenschaften, Frankfurt am Main.

WONG, B.K.; LAI, VINCENT S. UND LAM J. (2000): A bibliography of neural network business applications research: 1994 - 1998, Computers & Operations Research, 27 (2000) S. 1045 - 1076.

WU, C. UND X.-M. WANG (2000): A Neural Network Approach for Analysing Small Business Lending Decisions, Review of Quantitative Finance and Accounting, 15 (2000), S. 259 - 276.

ZADEH, L. (1965): Fuzzy Sets, Information and Control 8, S. 338 - 353.

ZELL, A. (1994): Simulation Neuronaler Netze, Bonn.

ZIMMERMANN, H.G. (1994): Neuronale Netze als Entscheidungskalkül, in REHKUGLER, H. UND H.G. ZIMMERMANN (1994): Neuronale Netze in der Ökonomie, München.

ZIMMERMANN, H.-J. (1987): Fuzzy-Sets, Decision Making and Expert Systems, Boston.

Input-Variablen	Einheit	Definition
Ertrag/Rentabilität		
Gewinn (zeitraumechter) K 1	DM je Unternehmen	<i>Zweckertrag - Zweckaufwand</i>
Cash flow K 2	DM je Unternehmen	<i>Gewinn (K1) + Abschreibungen</i>
Eigenkapitalveränderung K 3	DM je Unternehmen	<i>Gewinn (K1) + Einlagen – Entnahmen</i>
Eigenkapitalrentabilität K 4	Prozent	$\frac{\text{kalkulatorischer Gewinn} + \text{Zinsansatz}}{\text{Eigenkapital} - \text{Grund und Bodenvermögen}}$
Gesamtkapitalrentabilität K 5	Prozent	$\frac{\text{kalkulat. Gewinn} + \text{Zinsaufwand} + \text{Zinsansatz}}{\text{Gesamtkapital} - \text{Grund und Bodenvermögen}}$
dyn. Gesamtkapitalrent. K 6	Prozent	$\frac{\text{Cash flow (K2)} + \text{Zinsaufwand}}{\text{Gesamtkapital} - \text{Grund und Bodenvermögen}}$
Umsatzrentabilität K 7	Prozent	$\frac{\text{kalkulatorischer Gewinn}}{\text{Umsatz}}$
Wachstum		
Nettoinvestitionsquote K 8	Prozent	$\frac{\text{Nettoinvestition}}{\text{Bilanzsumme}}$
Durchschnittliche Nettoinvestitionen K 9	DM je Unternehmen	$\frac{\text{Nettoinvestition}_i + \text{Nettoinv.}_{i+1} + \text{Nettoinv.}_{i+2}}{3}$ <i>mit i = Wj 91/92</i>
Umsatzwachstum K 10	Prozent	$\frac{\text{Umsatz}_{i+2} - \text{Umsatz}_{i+1}}{\text{Umsatz}_{i+1}} + \frac{\text{Umsatz}_{i+1} - \text{Umsatz}_i}{\text{Umsatz}_i}$ 2 <i>mit i = Wj 91/92</i>
Entwicklung FK K 11	DM je Unternehmen	$\frac{(\text{Fk}_{i+2} - \text{Fk}_{i+1}) + (\text{Fk}_{i+1} - \text{Fk}_i)}{2}$ <i>mit i = Wj 91/92</i>

Finanzierungskraft		
Ausschöpfung der Kapitaldienstgrenze K 12	Prozent	$\frac{\text{Zinsaufwand} + \text{Tilgung}}{\text{Eigenkapitalveränderung (K4)} + \text{Zinsaufwand}}$
Zinsen K 13	Prozent	$\frac{\text{Zinsaufwand}}{\text{Fremdkapital}}$
Dyn. Verschuldungsgrad K 14	Jahre	$\frac{\text{Fremdkapital}}{\text{Cash flow (K2)}}$
Vermögensanalyse		
Umlaufintensität K 15	Prozent	$\frac{\text{Umlaufvermögen}}{\text{Bilanzsumme}}$
Grund- u. Bodenanteil K 16	Prozent	$\frac{\text{Grund – und Bodenvermögen}}{\text{Bilanzsumme}}$
Anlageintensität K 17	Prozent	$\frac{\text{Anlagevermögen}}{\text{Bilanzsumme}}$
Kapitalanalyse		
Fremdkapitalanteil K 18	Prozent	$\frac{\text{Fremdkapital}}{\text{Gesamtkapital}}$
Vergleich Kapital – Vermögen		
Liquidität 3. Grades K 19	Prozent	$\frac{\text{Umlaufvermögen}}{\text{kurzfristiges Fremdkapital}}$
Deckungsgrad A K 20	Prozent	$\frac{\text{Eigenkapital}}{\text{Anlagevermögen}}$

Finanzielle Effizienz		
Unternehmensertrag zu Vermögen K 21	Prozent	$\frac{\text{Unternehmensertrag}}{\text{Bilanzsumme}}$
Gewinn zu Unternehmensaufwand K 22	Prozent	$\frac{\text{kalkulatorischer Gewinn}}{\text{Unternehmensaufwand}}$
Abschreibung zu Gewinn K 23	Prozent	$\frac{\text{Abschreibung}}{\text{kalkulatorischer Gewinn}}$
Zinsdeckung K 24	Prozent	$\frac{\text{Zinsaufwand}}{\text{kalkulatorischer Gewinn} + \text{Zinsaufwand}}$
Allgemein		
LF K 25	ha	<i>Landwirtschaftliche Fläche</i>
Abnutzungsgrad der Maschinen K 26	Prozent	$\frac{\text{Zeitwert des Maschinenvermögens}}{\text{Neuwert des Maschinenvermögens}}$