

XI: FALLSTUDIEN ZUM PRAKTISCHEN EINSATZ VON NEURONALEN NETZWERKEN

XI.1 Einführung

Eine der interessantesten Eigenschaften von neuronalen Netzwerken ist ihre Fähigkeit, aus Beispielen, z.B. aus experimentellen Daten, zu lernen. (Einen guten Überblick über die verschiedenen Lernverfahren gibt z.B. Referenz [1]). Im Vergleich mit den traditionellen Methoden der Informationsverarbeitung bringen solche Systeme deshalb vor allem dort Vorteile, wo eine analytische Modellierung unmöglich oder sehr aufwendig ist. Die bisherigen Erfahrungen und Ergebnisse haben gezeigt, dass selbst relativ einfache neuronale Netzwerke in der Lage sind, komplexe Probleme aus verschiedenen Anwendungsbereichen effizient und ökonomisch zu lösen, falls nur genügend viele Lernbeispiele zur Verfügung stehen.

Voraussetzung für einen optimalen Einsatz von neuronalen Netzwerken sind allerdings eine intelligente Vorverarbeitung der Lerndaten und eine auf das Problem abgestimmte Wahl der Topologie und der Grösse der verwendeten Netzwerke. Das Lern- und Verallgemeinerungsverhalten von neuronalen Netzwerken kann zudem durch eine Reihe von Faktoren und Implementierungsdetails beeinflusst werden, z.B. durch eine geeignete Darstellung und Skalierung der Input- und Outputdaten oder durch die Wahl der Aktivierungsfunktionen, etc. Dabei zeigt sich, dass es bei der Entwicklung von Informationsverarbeitungssystemen immer wesentliche Aspekte gibt, die nur problemspezifisch, d.h. im Zusammenhang mit repräsentativen Prototyp-Anwendungen untersucht werden können.

In den folgenden Abschnitten diskutieren wir deshalb einige konkrete Beispiele zum Einsatz von neuronalen Netzwerken in der Industrieforschung. Die entsprechenden Projekte, die im ABB Forschungszentrum in Baden-Dättwil durchgeführt wurden, beziehen sich alle auf Feed-forward-Netzwerke, befassen sich aber mit sehr unterschiedlichen Problemstellungen:

- Modellierung und Optimierung von Materialeigenschaften
- Klassifizierung von Isolationsdefekten
- Lastprognose in elektrischen Netzen.

Die praktischen Erfahrungen, die wir dabei gemacht haben, demonstrieren einerseits das Potential von Informationsverarbeitungsmethoden, die auf künstlichen neuronalen Netzwerken basieren, offenbaren andererseits aber auch deren Grenzen und Unzulänglichkeiten.


XI.2 Modellierung und Optimierung von Materialeigenschaften

Die anwendungsspezifische Optimierung von Materialeigenschaften ist ein ständig wiederkehrendes Problem der Industrieforschung. Der experimentelle Aufwand bei entsprechenden Untersuchungen ist oft beträchtlich und sehr kostenintensiv. Deshalb versucht man, diesen Aufwand mit Hilfe von geeigneten Modellierungsverfahren zu minimieren. Als illustratives Beispiel für ein solches Problem beschreiben wir in diesem Abschnitt unsere Erfahrungen mit dem Einsatz von neuronalen Netzwerken bei der Optimierung der Zusammensetzung von sogenannten "ZnO-Varistoren" [2, 3].

Optimierung der elektrischen Eigenschaften von ZnO-Varistoren

Varistoren (variable resistors) sind keramische Bauelemente für den Überspannungsschutz auf allen Spannungsebenen, von einigen Volt bis hin zu Megavolt. Speziell im Mittel- und Hochspannungsbereich basieren Ableiter heute vorwiegend auf solchen Schutzelementen.

Varistoren bestehen zur Hauptsache aus ZnO, einem Oxid-Halbleiter mit grosser Energielücke. Durch Zugabe geeigneter Dotierstoffe kann diesen Materialien im polykristallinen Verbund eine stark nichtlineare Strom-Spannungs-Kennlinie verliehen werden:



Beim Überschreiten einer materialabhängigen Schwellenspannung schalten solche Elemente innert Nanosekunden und reversibel von einem isolierenden in einen gut leitenden Zustand. Diese Strom-Spannungs-Charakteristik wird durch die Dotierung und durch die Temperaturführung beim Sinterprozess festgelegt. Dabei werden bis zu zehn verschiedene Dotierstoffe verwendet, welche in sehr unterschiedlichen Konzentrationsbereichen (ppm bis %) vorliegen. Der Varistor-Hersteller sieht sich deshalb mit der äusserst komplexen Aufgabe konfrontiert, ein bis zu 10-komponentiges System bezüglich verschiedener elektrischer Zielgrössen zu optimieren.

Die wichtigsten dieser Zielgrössen sind die Verlustleistung P_V bei der Betriebsspannung U_V , das Spannungsverhältnis $R_V = U_P/U_B$ zwischen einer durch einen Normstrompuls erzeugten Überspannung U_P und der Durchbruchspannung U_B , sowie der Nichtlinearitätskoeffizient $\alpha = d(\log J)/d(\log U)$. Um eine gute thermische Stabilität zu gewährleisten, muss die Verlustleistung P_V so niedrig wie möglich sein, und auch das Spannungsverhältnis R_V , welches die Güte des Überspannungsschutzes charakterisiert, sollte möglichst klein sein. Der Nichtlinearitätskoeffizient α hingegen sollte möglichst gross sein.

Eine weitere Anforderung an einen guten Varistor ist die Langzeit-Stabilität, welche durch $dP_V/dt \leq 0$ ausgedrückt wird, wobei sich dP_V/dt auf die zeitliche Ableitung der Verlustleistung P_V bezieht, gemessen nach einer Betriebsdauer von 500 oder 1000 Stunden.

Die Abhängigkeit der elektrischen Kenngrößen von den Konzentrationen der Dotierstoffe ist sehr nichtlinear, und es bestehen starke Korrelationen zwischen den Einflüssen von verschiedenen Dotierelementen. Um dem Zusammenhang zwischen Zusammensetzung und elektrischen Kenngrößen auf die Spur zu kommen, wurde zuerst der Einfluss jedes Dotierelementes einzeln untersucht und dann ein Satz von 5 Dotierstoffen ausgewählt, welche einen besonders starken Einfluss auf das elektrische Verhalten zeigten. Mit diesen 5 Dotierkomponenten wurde dann ein aufwendiger systematischer Variationsversuch durchgeführt, welcher auch die Wechselwirkungen zweiter und höherer Ordnung aufzeigen sollte. Insgesamt standen schlussendlich etwa 50 Datensätze

$[c_1, c_2, c_3, c_4, c_5; P_V, R_V, \alpha, dP_V/dt]$

zur Verfügung, wobei sich die c_i auf die Konzentrationen der Dotierelemente beziehen.

Bekannte Verfahren der statistischen Analyse von experimentellen Daten, z.B. die Bestimmung von sogenannten "Effekten" (verbunden mit einem Signifikanztest) erwiesen sich aber als untauglich. Das hängt unter anderem damit zusammen, dass entsprechende Analysen lineare Zusammenhänge und die Additivität der Effekte voraussetzen. Im vorliegenden Fall war die Abhängigkeit von den Konzentrationen der Dotierstoffe aber extrem nichtlinear, und es stellte sich heraus, dass Wechselwirkungen höherer Ordnung gleich stark sein konnten wie die Einflüsse der Einzelelemente.

Deshalb haben wir versucht, die Lern- und Verallgemeinerungsfähigkeiten von neuronalen Netzwerken auszunützen, um dieses schwierige Modellierungs- und Optimierungsproblem in den Griff zu bekommen.

Modellierung von ZnO-Varistoren mit neuronalen Netzwerken

Für die Modellierung des Zusammenhangs zwischen der Zusammensetzung und den elektrischen Eigenschaften von ZnO-Varistoren haben wir Feedforward-Netzwerke mit einer oder zwei Schichten von Hidden Units verwendet, die mit dem Error-Backpropagation Lernalgorithmus trainiert wurden. Die Inputs bezogen sich auf die Konzentrationen der 5 Dotierelemente und die Outputs auf die elektrischen Kenngrößen P_V , R_V , α und dP_V/dt . Wegen des grösseren Abbildungsbereichs wurden die Aktivierungsfunktionen der Outputneuronen **linear** gewählt, diejenigen der Hidden Units aber als **sigmoide** Funktionen mit einem Wertebereich zwischen -1 und $+1$.

• Vorverarbeitung der Input und Outputdaten

Eine Vorverarbeitung der Inputdaten (Dotierkonzentrationen) war aus zwei Gründen wichtig:

- Die einzelnen Konzentrationen bewegen sich in sehr unterschiedlichen Bereichen (von ppm bis %).
- Die Verteilung der Daten über den interessierenden Konzentrationsbereich war in vielen Fällen sehr inhomogen.

Die Inputdaten wurden deshalb so normiert, dass der interessierende Konzentrationsbereich für alle Dotierelemente auf $[-1, +1]$ abgebildet wurde. Die Normierungsfunktionen wurden aber nichtlinear gewählt, und zwar jeweils so, dass die Verteilung der Messwerte über das Intervall $[-1, +1]$ möglichst gleichmässig war.

Auch die Outputdaten (elektrische Kenngrößen) wurden so normiert, dass der interessierende Bereich ungefähr auf $[-1, +1]$ abgebildet wurde (obwohl die Outputneuronen linear gewählt wurden). Bei der Wahl der (wiederum nichtlinearen) Normierungsfunktionen spielten die folgenden Aspekte eine wesentliche Rolle:

- Schlechte Messwerte (z.B. hohe Werte für P_V , R_V oder dP_V/dt) wurden auf einen Bereich nahe bei $+1$ komprimiert. Damit wurde verhindert, dass die schlechten (und damit uninteressanten Werte) beim Lernprozess eine dominierende Rolle spielen.
- Auch Intervalle mit wenigen Messdaten wurden komprimiert, da dort keine genügend genaue Modellierung zu erwarten war.

• Wahl der Netzwerkarchitektur

Die Suche nach geeigneten Netzarchitekturen beschränkte sich auf Multilayer-Perceptrons mit einer oder zwei Schichten von Hidden Units. Neben Netzwerken mit einem Output (jeweils eine der elektrischen Kenngrößen) wurden auch solche mit 3 Outputs (P_V , R_V und α) in Betracht gezogen, da diese 3 Kenngrößen miteinander korreliert sind.

Die Bestimmung von optimalen Architekturen wurde in zwei Schritten durchgeführt. Zunächst wurde eine grosse Anzahl von Netzwerken mit den etwa 50 zur Verfügung stehenden Lernbeispielen trainiert und bezüglich ihrer Lernfähigkeit (quadratischer Outputfehler) miteinander verglichen. Dabei stellte sich heraus, dass Netzwerke mit nur einem Hidden Layer die Lernbeispiele nur schlecht approximieren konnten.

Von den geeignet erscheinenden Netzwerken mit einem bzw. drei Outputs wurden je die 3 besten (in Bezug auf den Lernfehler) ausgewählt und einem speziellen Crossvalidation Verfahren unterzogen. Dabei wurde die Verallgemeinerungsfähigkeit der Netze nicht wie üblich anhand von Testbeispielen untersucht, sondern anhand ihrer Interpolationsfähigkeit zwischen geeignet ausgewählten Messdaten.

Für die Zielgrößen P_V , R_V und α erwiesen sich schliesslich das 5641- und das 5583- Netz als optimale Architekturen, für dP_V/dt ebenfalls das 5641-Netz und zusätzlich noch das 5531-Netz. [Dabei bezeichnet die Nomenklatur 5641 z.B. ein Netz mit 5 Inputs, 6 Neuronen im ersten Hidden Layer, 4 Neuronen im zweiten Hidden Layer und einem Output.]

Eine ergänzende Studie hat ferner gezeigt, dass der Zusammenhang zwischen Dotierung und elektrischen Eigenschaften mit neuronalen Netzwerken wesentlich zuverlässiger modelliert werden kann als mit einer polynomialen Regressionsanalyse.

Vorhersage von optimalen Zusammensetzungen

Im eigentlichen Optimierungsprozess ersetzen nun die trainierten Netzwerke das Durchführen von aufwendigen Experimenten. Durch eine systematische Variation der Inputdaten können mit Hilfe der Netzwerk-Vorhersagen Konzentrationsbereiche für die Dotierelemente identifiziert werden, die zu optimalen Werten für die elektrischen Kenngrößen führen sollten.

• Vorgehen

Zunächst wurde der interessierende Bereich im 5-dimensionalen Zusammensetzungs-Raum mit einem Raster von $2 \cdot 13^5 = 742'586$ Gitterpunkten überdeckt. Aus diesen 742'586 Zusammensetzungen wurden dann diejenigen bestimmt, für welche die Vorhersagen für die Werte der elektrischen Kenngrößen vorgegebene Mindestanforderungen erfüllten. Dabei wurden nur solche Zusammensetzungen berücksichtigt, bei denen die geforderten Eigen-

schaften von 4 verschiedenen Netzwerken bestätigt wurden. Der Mittelwert der 4 individuellen Vorhersagen bildete dann die eigentliche Vorhersage für die elektrischen Kenngrößen.

So ergab sich schliesslich ein Datensatz von etwa 2000 Zusammensetzungen mit guten (prognostizierten) elektrischen Eigenschaften. Je nach Einsatzgebiet des Varistors erhalten die Werte von P_V , R_V , α und dP_V/dt andere Prioritäten, und gemäss den entsprechenden Anforderungsprofilen konnten nun aus dem Datensatz für jedes Einsatzgebiet optimale Varistor-Zusammensetzungen bestimmt werden.

• Resultate

Als Beispiel sind in der folgenden Tabelle die Resultate für Hochspannungsvaristoren zusammengefasst. Hier wurden 3 verschiedene Zusammensetzungen (A, B und C) identifiziert, die zu wesentlich verbesserten Eigenschaften führen sollten:

Zusammensetzung	P_V		R_V		α	
	Prog.	Exp.	Prog.	Exp.	Prog.	Exp.
A	- 25%	- 28%	- 3.1%	- 7.9%	+ 48%	+ 65%
B	- 15%	- 36%	- 2.5%	- 8.0%	+ 30%	+ 78%
C	- 41%	- 37%	- 2.5%	- 4.6%	+ 74%	+ 96%

Die Tabelle zeigt die prognostizierten (Prog.) und danach experimentell gemessenen (Exp.) Verbesserungen der Kenngrößen P_V , R_V und α in Bezug auf das bis dahin verwendete Referenz-Material. Alle drei Zusammensetzungen erfüllten zudem das Langzeit-Stabilitätskriterium $dP_V/dt \leq 0$ nach 1000 Stunden Betriebsdauer.

Bei der Bewertung der erzielten Verbesserungen muss berücksichtigt werden, dass das Verbesserungspotential der einzelnen Kenngrößen sehr unterschiedlich ist. Die Tatsache, dass die gemessenen Verbesserungen durchwegs grösser sind als prognostiziert, lässt sich zumindest teilweise mit der eher konservativen Beurteilung der Netzwerk-Vorhersagen erklären.

Adaptive Planung von Experimenten

In einem weiteren Projekt (siehe [4]), welches alle 10 Dotierelemente umfasste, ging es darum, eine bereits sehr gute Varistor-Mischung bezüglich 8 elektrischen Kenngrößen weiter zu verbessern und dabei gleichzeitig die Materialkosten zu reduzieren. Bei diesem noch wesentlich komplexeren Problem standen zu Beginn nur 34 Lerndaten zur Verfügung. Es stellte sich deshalb die Frage, bei welchen Zusammensetzungen weitere Messungen durchgeführt werden sollten, um schliesslich eine möglichst optimale Mischung zu finden. Um die Anzahl der notwendigen Messungen zu minimieren, haben wir eine adaptive Strategie gewählt, wobei die Modellierung wieder mit Hilfe von neuronalen Netzwerken durchgeführt wurde.

Die Netzwerke wurden nach jeweils 4 Messungen mit dem erweiterten Datensatz trainiert und dann analysiert. Danach wurden 4 neue Zusammensetzungen für die nächsten Messungen vorgeschlagen, usw. In der ersten Phase des Projekts erfolgte die Auswahl dieser Zusammensetzungen so, dass der Informationsgewinn maximal war, d.h. die neuen Experimente wurden mit denjenigen Zusammensetzungen durchgeführt, bei denen die Modellierungs-Unsicherheit


der Netzwerke noch am grössten war. Erst nachdem genügend Daten zur Verfügung standen, wurden auch Zusammensetzungen vorgeschlagen, für welche die neuronalen Netzwerke optimale Eigenschaften vorhersagten

Nach nur etwa 140 Experimenten konnten mit dieser adaptiven Strategie 9 neue Varistor-Zusammensetzungen mit zum Teil beträchtlich verbesserten Eigenschaften identifiziert werden. Zum Beispiel konnte die Verlustleistung P_V im Durchschnitt um etwa 35% gesenkt werden, und der Nichtlinearitätskoeffizient α wurde um fast 60% erhöht. Zudem waren die Materialkosten bei allen neuen Zusammensetzungen tiefer als bei der damals verwendeten Mischung.

XI.3 Klassifizierung von Isolationsdefekten

Die lokale Verschiebung von Elektronen und Ionen in einem Isolator unter dem Einfluss eines genügend starken elektrischen Feldes bezeichnet man als elektrische Teilentladung. Elektrische Teilentladungen treten insbesondere dort auf, wo die Isolation Defekte aufweist. Sie spielen daher eine wichtige Rolle bei der Diagnose von technischen Isolationssystemen.

Mit geeigneten Messapparaturen können die Stärke q (verschobene Ladung) und die Phasenlage φ von elektrischen Teilentladungen bestimmt werden. Durch das Registrieren einer grossen Anzahl von solchen Messungen erhält man dann eine Teilentladungs-Statistik $\rho(\varphi, q)$, die z.B. als zweidimensionales Teilentladungsmuster dargestellt werden kann:



Ein Teilentladungsmuster ist charakteristisch für einen bestimmten Defekttyp und einen bestimmten Entladungsmechanismus. Die Identifikation von verschiedenen Defekten kann so auf ein Mustererkennungs-Problem zurückgeführt werden.

Das Ziel des hier beschriebenen Projektes [5, 6] war, diese Mustererkennung mit Hilfe von neuronalen Netzwerken zu automatisieren und zu zeigen, dass entsprechende Systeme fähig sind, solche Teilentladungsmuster mit einem akzeptablen Klassifizierungsfehler ($< 1\%$) zu erkennen.

Simulation von Teilentladungsmustern

Zu Beginn unseres Projektes wurden die Verfahren zur Messung von Teilentladungsmustern gerade entwickelt, so dass erst eine sehr beschränkte Zahl von gemessenen Mustern zur Verfügung stand. Deshalb entschlossen wir uns, die Untersuchungen mit Hilfe von simulierten Teilentladungsmustern durchzuführen.

Mit geeigneten stochastischen Entladungsmodellen kann man eine Vielzahl von realistischen Situationen beschreiben, und wir haben schliesslich acht Klassen von Teilentladungsmustern ausgewählt, zu denen es auch gemessene Beispiele gab. Für jede Klasse simulierten wir etwa 25 Muster (mit je 4000 Entladungen), so dass unser Basis-Lernset aus etwa 200 Mustern bestand.

Zusätzlich haben wir jedes dieser Muster noch mit drei verschiedenen Sorten von Rauschen überlagert. Das ergab dann einen zweiten, erweiterten Lernsatz von total 800 Mustern. Das Rauschen bestand aus 2000 zufälligen Entladungen, die phasenunabhängig auftreten und deren Wahrscheinlichkeit exponentiell mit $|q|$ abnimmt. Die 4000 Entladungen eines verrauschten Musters stammen also je zur Hälfte aus dem eigentlichen Muster und aus dem Rauschen.

Erkennung von Teilentladungsmustern mit neuronalen Netzwerken

Das Mustererkennungsproblem bestand nun also darin, ein Teilentladungsmuster einer von acht Klassen zuzuordnen. Zur Lösung dieses Problems haben wir Multilayer-Perceptrons ver-

wendet, die mit einem Error-Backpropagation-Lernalgorithmus trainiert wurden. Die Verallgemeinerungsfähigkeit der trainierten Netze wurde mit Hilfe eines Crossvalidation-Verfahrens abgeschätzt (siehe Abschnitt 4.2.2). Die entsprechenden Resultate werden in Abschnitt 4.3 diskutiert und mit denjenigen von alternativen Mustererkennungsverfahren verglichen.

• Vorverarbeitung und Informationsreduktion


Die gemessenen (und die simulierten) Teilentladungsmuster wurden in 256×256 Häufigkeitswerte (lokale Entladungshäufigkeiten) aufgelöst. So viele Inputdaten würden aber zu sehr grossen Netzwerken führen, was erstens eine sehr lange Trainingszeit zur Folge hätte, und zweitens hätten solche Netze wegen der vielen anpassbaren Parameter ein sehr schlechtes Verallgemeinerungsverhalten. Deshalb musste zuerst eine geeignete Informationsreduktion durchgeführt werden.

Wegen der Symmetrie der Teilentladungsmuster wurden für die Mustererkennung nur die Entladungen mit $q > 0$ berücksichtigt. Das entsprechende Fenster ist die $\varphi \times q$ - Fläche

$$[315^\circ, 180^\circ] \times [0, 2],$$

wobei φ modulo 360° zu verstehen ist. Dieses Fenster enthält immer noch eine sehr grosse Anzahl (160×128) Punkte.

Aus den verschiedenen in Betracht gezogenen Methoden, diese Information zu reduzieren, hat sich die Reduktion der zweidimensionalen Häufigkeitsverteilung auf grob diskretisierte Randverteilungen $r(\varphi)$ und $r(q)$ am besten bewährt. Dabei wurden $r(\varphi)$ und $r(q)$ durch z.B. nur je 8 Werte charakterisiert, die der Summe der Entladungshäufigkeiten in geeignet gewählten Streifen entsprachen. Für $r(\varphi)$ wurden die Streifen senkrecht zur φ -Achse gewählt ("kartesische Koordinaten"). Für $r(q)$ hat sich aber herausgestellt, dass eine problemangepasste, Sinus-förmige Streifenform zu besseren Resultaten führt als kartesische Streifen:




Mit dieser Vorverarbeitung wird die Information in den Teilentladungsmustern also auf z.B. $8+8 = 16$ Werte reduziert. In einem weiteren Schritt werden dann die 16 Inputwerte noch auf den Bereich $[-1, +1]$ reskaliert.


• Bestimmung der optimalen Netzwerkgrösse

Wir haben Netzwerke mit 16 ($= 8+8$), 24 ($= 12+12$) und 32 ($= 16+16$) Inputs und mit einer oder zwei Schichten von Hidden Units betrachtet. Die Anzahl der Outputneuronen war immer gleich 8, entsprechend den acht Klassen a bis h. Als Aktivierungsfunktion für die Outputneuronen wurde eine sigmoide Funktion mit dem Wertebereich (0, 1) gewählt.

Der Verallgemeinerungsfehler der untersuchten Netzwerke wurde mit Hilfe eines Crossvalidation-Verfahrens abgeschätzt, bei dem das Lernset in 10 zufällig ausgewählte Subsets unterteilt wurde. Als Fehlermass wurde hier der prozentuale Anteil falsch klassifizierter Muster verwendet. Es stellte sich heraus, dass Netzwerke mit zwei Schichten von Hidden Units schlechter verallgemeinern als solche mit nur einer Schicht. In der Folge haben wir uns auf solche Netzwerke beschränkt (siehe Figur),



und schliesslich noch die Anzahl der Neuronen im Hidden Layer optimiert. Die folgende Graphik illustriert die Resultate des Crossvalidation-Verfahrens für ein Netzwerk mit $8+8 = 16$ Inputs, bei dem die Anzahl der Hidden Units zwischen 6 und 30 variiert wurde:



Während der Trainingsfehler mit zunehmender Anzahl n_H von Hidden Units monoton abnimmt, und ab $n_H = 20$ sogar Null wird, steigt der Verallgemeinerungsfehler für grössere n_H wieder an. Die optimale Anzahl von Hidden Units liegt hier also zwischen etwa $n_H = 12$ und $n_H = 20$.

Resultate und Diskussion

Einige Resultate der oben beschriebenen Crossvalidation-Tests sind in der folgenden Tabelle zusammengestellt:

Netzwerk	Lernset	r(q)-Reduktion	Testfehler [%]
24-8-8	ohne Rauschen	Sinus	7.98
24-8-8	verrauscht	Sinus	0.75
24-12-8	ohne Rauschen	Sinus	6.48
24-12-8	verrauscht	Sinus	0.25
16-8-8	verrauscht	karthesisch	3.24
16-8-8	verrauscht	Sinus	0.62
16-6-8	verrauscht	Sinus	1.62
16-8-8	verrauscht	Sinus	0.62
16-10-8	verrauscht	Sinus	0.50
16-12-8	verrauscht	Sinus	0.25
16-20-8	verrauscht	Sinus	0.25
16-24-8	verrauscht	Sinus	0.37
16-30-8	verrauscht	Sinus	0.62

Diese Ergebnisse bestätigen unsere Erwartungen:

- Ein durch überlagertes Rauschen vergrößerter Lernset führt zu einem besseren Lern- und Verallgemeinerungsverhalten.
- Bei der Reduktion auf die r(q)-Randverteilung bewähren sich Sinus-Koordinaten viel besser als kartesische, da sie den Musterstrukturen angepasst sind.
- Zu kleine Netzwerke können die gestellte Aufgabe nur ungenügend lernen, aber auch zu grosse Netze verallgemeinern schlecht, da sie sich zu stark auf die Trainingsbeispiele spezialisieren.

Die nächste Tabelle zeigt schliesslich noch einen Vergleich verschiedener Lernverfahren:

Verfahren	Testfehler [%]	
	ohne Rauschen	mit Rauschen
Multilayer-Perceptron (24-12-8)	6.5	0.25
Einfaches Perceptron (24-8)	12.5	3.49
3-Nearest-Neighbor	13.4	0.62
Learning Vector Quantization	14.9	8.83

Das Multilayer-Perceptron erkennt die Muster in beiden Fällen (verrauschte und nicht-verrauschte Muster) am besten. Das einfache 3-Nearest-Neighbor Verfahren liegt bei den verrauschten Mustern klar an zweiter Stelle. Bei den nicht-verrauschten Mustern schneidet es aber etwa gleich schlecht ab wie die beiden andern Verfahren.

Nach Abschluss der Studie wurde dann noch ein Test mit realen Mustern durchgeführt. Aus Laborexperimenten und aus Messungen in Kraftwerken standen 19 Muster zur Verfügung, die von Experten den 8 Klassen zugeordnet werden konnten.

Ein 24-8-8 Netzwerk, das nur anhand von simulierten (verrauschten) Mustern trainiert worden war, klassifizierte dann 15 dieser realen Muster (d.h. etwa 80%) gleich wie die Experten. Das zeigt, dass die Mustererkennung mit neuronalen Netzwerken auch unter realen Bedingungen zufriedenstellend funktioniert und bestätigt gleichzeitig, dass die simulierten Muster wirklich repräsentativ sind für reale Teilentladungsmuster.

XI.4 Lastprognose in elektrischen Netzen

Zuverlässige Lastprognosen sind eine wichtige Voraussetzung für die Planung der Stromproduktion und für den Stromhandel, insbesondere im Hinblick auf die Deregulierung der Strommärkte. Solche Prognosen werden heute vorwiegend von Experten mit grossem Erfahrungswissen erstellt. Dabei spielen Mustererkennungs-Prinzipien oft eine wesentliche Rolle.


In den letzten Jahren hat das Interesse an der Anwendung von statistischen Methoden für die Vorhersage von elektrischen Lasten stark zugenommen. Viele der entsprechenden Studien befassen sich dabei mit dem Einsatz von neuronalen Netzwerken, wobei es sich allerdings oft um theoretische Arbeiten handelt, die für die praktische Anwendung nur beschränkte Bedeutung haben. Es existieren aber auch einige Tests mit solchen Modellen, die unter realistischen Bedingungen durchgeführt wurden.

Der Schritt von einem theoretischen zu einem praxistauglichen Modell ist oft der schwierigste Teil bei einem solchen Projekt. Die Prognosen müssen zuverlässig und genau sein (mindestens so gut wie die Expertenprognosen) und auch Ausnahmesituationen (z.B. Feiertage, etc.) berücksichtigen, ebenso die Besonderheiten der Region, für welche die Vorhersagen erstellt werden.

Die hier diskutierten Untersuchungen (siehe [7]) beziehen sich auf ein gemeinsames Projekt zwischen der EOS (Energie de l'Ouest-Suisse SA), der ETH Lausanne und der ABB.

Definition des Vorhersageproblems

Die EOS ist zuständig für die Erzeugung und Übertragung von elektrischer Energie in der Westschweiz. Das Versorgungsgebiet von EOS bzw. seiner fünf Partnergesellschaften umfasst eine Fläche von 5000 km² mit etwa 1 Million Einwohnern. Die Lastspitze liegt bei über 1000 MW.



Die gestellten Anforderungen an das zu entwickelnde Vorhersage-Modell können wie folgt zusammengefasst werden:

- Vorhersage der stündlichen Verbrauchsmittelwerte.
- Die Prognose wird jeweils um 07.00 Uhr erstellt und bezieht sich in der Regel auf die 24 Stunden des folgenden Tages. Am Freitag muss hingegen eine Prognose für Samstag, Sonntag und Montag erstellt werden.
- Die Genauigkeit der Vorhersage sollte besser sein als die der bisherigen Verfahren.

Bestimmung eines geeigneten Vorhersagemodells

Die wichtigsten Schritte bei der Bestimmung eines geeigneten Modells für die stündliche Lastprognose können wie folgt umschrieben werden:

- Auswahl und Vorverarbeitung der Inputgrößen.
- Zerlegung der stündlichen Last in verschiedene Komponenten.
- Modellierung der einzelnen Komponenten.
- Bestimmung der Modellparameter mit Hilfe von Trainingsdaten.

Zur Bestimmung von relevanten Inputgrößen wurden in erster Linie Korrelationsanalysen durchgeführt. Daneben spielten auch die Erfahrung von Experten und die Verfügbarkeit genügend genauer Daten eine nicht unwesentliche Rolle. Als wichtigste Inputgrößen erwiesen sich schliesslich die vor einer Woche (am gleichen Wochentag) gemessenen Lastwerte, die Lastwerte der letzten zwei Tage, die Temperatur-Minima und -Maxima des Vortages (gemessen an verschiedenen Orten des Versorgungsbereichs), die Temperaturprognosen für die Vorhersage-Tage, sowie Indikatoren für den Wochentag und den Jahrestag.

Für die Modellierung der stündlichen Last $L(h)$ wählten wir eine Zerlegung in vier Komponenten:

$$L(h) = T + S(d, h) + W(wd, h) + R(h), \quad [h = 1, 2, \dots, 24],$$

T = Trend-Komponente

S = Saisonale Komponente (d = Jahrestag: 1, ..., 365)

W = Wochentags-Komponente (wd = Wochentag; 1, ..., 7)

R = Residuen-Komponente


Die Trend-Komponente beschreibt den jährlichen Zuwachs des Elektrizitätsverbrauchs. Sie kann in unserem Fall vernachlässigt werden, da wir die Modellparameter mehrmals pro Jahr neu estimieren. Die saisonale Komponente kann durch einen Sinus-förmigen Ansatz modelliert werden. Sie hängt hauptsächlich von den jahreszeitlichen Temperaturschwankungen ab. Die Wochentags-Komponente bezieht sich auf das mittlere Lastprofil für die verschiedenen Wochentage. Diese drei Komponenten beschreiben das mittlere Verhalten des Elektrizitätsbedarfs, und ihre Parameter werden mit Hilfe von linearen Regressionsverfahren aus historischen Daten ermittelt.

Zur Modellierung der Residuen-Komponente, welche die Abweichungen vom mittleren Verhalten beschreibt, haben wir ein Multilayer-Perceptron verwendet. Die Inputgrößen für dieses neuronale Netzwerk beziehen sich auf die Abweichungen der gemessenen Last- und Temperaturwerte von ihren mittleren Verhalten, sowie auf Temperaturprognosen und Tagesindikatoren. Als Lernverfahren wurde Error-Backpropagation verwendet, wobei 20% der Trainingsdaten (historische Last- und Temperaturwerte über die letzten 2 Jahre) zum Testen der Verallgemeinerungsfähigkeit benutzt wurden.


Online-Test und Diskussion der Ergebnisse

Um die Einsatztauglichkeit unseres Prognosesystems unter realen Bedingungen abzuklären, haben wir einen 3-monatigen Online-Test durchgeführt. Da das Lastverhalten und zum Teil auch die Wetterbedingungen in den verschiedenen Regionen sehr unterschiedlich sind, haben wir für alle 5 Partnergesellschaften von EOS ein separates Prognose-Modell entwickelt. Die Gesamtprognose für das EOS-Gebiet war dann die Summe der Einzelprognosen.


Die Testumgebung und der Ablauf der täglichen Berechnung und Kommunikation der Prognosewerte ist im folgenden Schema skizziert:



Die Auswertung der Testresultate zeigt, dass der Prognosefehler der Modellvorhersagen im Mittel um etwa 20-30% kleiner war als derjenige der Expertenprognosen, die parallel dazu erstellt wurden (siehe Graphiken A und B). Über die Testperiode betrug der mittlere Prognosefehler des Modells etwa 2.2%. Wie erwartet konnten aber Tageszeiten und Wochentage identifiziert werden, für die eine Vorhersage wesentlich schwieriger ist als für andere Zeiten bzw. Wochentage. Dabei ist zu beachten, dass z.B. der Horizont für die Montags-Vorhersage drei mal länger ist als während der Woche.




A) Prognosefehler nach Wochentagen



B) Prognosefehler nach Tageszeiten

Diese Resultate beziehen sich auf die Prognosen für das gesamte EOS-Gebiet. Eine Analyse der Einzelprognosen (siehe Graphik C) zeigt, dass sich in der Vorhersagegenauigkeit für die verschiedenen Regionen deutliche Unterschiede feststellen lassen. Der Prognosefehler variiert hier zwischen 2.3% (SEL, SRE) und 3.3% (CVE). Die schlechteren Resultate beziehen sich auf ländliche Gebiete bzw. auf Gegenden mit Rundsteuerungen (z.B. für elektrische Heizungen).



C) Prognosefehler nach Regionen und Einfluss der Genauigkeit der Temperaturvorhersage

Weiter befassten wir uns auch mit der Frage, wie stark die Resultate von der Genauigkeit der Temperaturprognose beeinflusst werden. Da keine historischen Daten für Temperaturprognosen vorlagen, wurde das neuronale Netzwerk mit gemessenen Temperaturwerten trainiert. Im Online-Betrieb muss man aber natürlich mit Vorhersagen arbeiten, die mit zunehmendem Prognosehorizont immer ungenauer werden. Eine nachträgliche Auswertung der Testdaten mit den tatsächlich gemessenen Temperaturen hat dann ergeben, dass die Fehler bei der Lastprognose mit genaueren Temperaturvorhersagen noch um etwa 10% reduziert werden könnten (siehe Graphik C), d.h. im Fall der totalen EOS-Last von 2.2% auf etwa 1.9%.

Die Ziele des Projekts wurden, aus der Sicht aller Projektteilnehmer, in jeder Hinsicht erreicht. Das gilt insbesondere auch für den Nachweis der Praxistauglichkeit des entwickelten Lastvorhersage-Modells. Mit einer Weiterentwicklung dieses Modells bietet ABB heute den Energieversorgungsunternehmen die Lastprognose als Dienstleistung über das Internet an (siehe <http://abb.prediction-partner.ch>).

XI.5 Schlussfolgerungen

Die beschriebenen Fallstudien, und eine Reihe von weiteren Projekten haben uns gezeigt, dass neuronale Netzwerke in vielen praktischen Anwendungen eine vielversprechende Alternative zu klassischen Methoden der Informationsverarbeitung darstellen. Neuronale Netzwerke machen die konventionellen Lösungsansätze natürlich keineswegs überflüssig, und oft lohnt es sich, verschiedene Verfahren miteinander zu kombinieren und neuronale Netzwerke nur für diejenigen Teilaspekte eines Problems einzusetzen, wo sie klare Vorteile bringen.

Ein fundiertes Verständnis der Lern- und Verallgemeinerungseigenschaften ist sicher eine wesentliche Voraussetzung für den effizienten Einsatz von neuronalen Netzwerken. In praktischen Anwendungen haben andere Aspekte aber oft einen ebenso grossen Einfluss auf die Leistungsfähigkeit von Lösungsansätzen, die auf der Verwendung von neuronalen Netzwerken basieren. Dazu gehören eine sorgfältige und problemangepasste Vorverarbeitung der Trainingsdaten, eine optimale Wahl der Architektur und Grösse der verwendeten Netzwerke und eine effiziente Trainings- und Teststrategie. In allen unseren Projekten haben wir die Erfahrung gemacht, dass es sich immer lohnt, das vorhandene Wissen über das zu lösende Problem so vollständig wie möglich in das Design der neuronalen Netzwerksysteme miteinzubeziehen.

Bei der Optimierung der Zusammensetzung von ZnO-Varistoren bestanden die Hauptprobleme in der Auswahl von geeigneten nichtlinearen Normierungsfunktionen für die Input- und Outputgrössen und in der Bestimmung von optimalen Netzwerkarchitekturen. Ferner haben wir die Tatsache, dass verschiedene (oder verschieden trainierte) Netzwerke unterschiedlich verallgemeinern, in zweierlei Hinsicht ausgenützt. Bei der Suche nach optimalen Zusammensetzungen haben wir immer mehrere Netze parallel benützt, um eine zuverlässigere Vorhersage zu erhalten, und bei der adaptiven Planung von Experimenten konnte die Varianz der Vorhersagen dazu verwendet werden, neue Experimente so vorzuschlagen, dass der erzielte Informationsgewinn möglichst gross wurde.

Bei der Klassifizierung von Isolationsdefekten stand die Informationsreduktion im Vordergrund. Dabei musste die Information in den Teilentladungsmustern so komprimiert werden, dass das neuronale Netzwerk nicht übertrainiert wurde, andererseits aber keine wesentlichen Merkmale der Muster verloren gingen. Ferner hat sich gezeigt, dass eine Verrauschung der Lernbeispiele das Lern- und Verallgemeinerungsverhalten signifikant verbessern kann.

Unser Modell für die Lastprognose in elektrischen Netzen ist schliesslich ein gutes Beispiel für den gezielten Einsatz von neuronalen Netzwerken. Die Komponenten, die das mittlere Lastverhalten bestimmen, haben wir mit klassischen Methoden abgeschätzt und nur die Abweichungen vom mittleren Verhalten mit einem neuronalen Netzwerk modelliert. Das führt zu einem viel problemloseren Lern- und Verallgemeinerungsverhalten, da sich das neuronale Netz nicht auch noch mit dem Lernen von Mustern befassen muss, die sich mit der Zeit kaum verändern.

Zusammenfassend können wir feststellen, dass die Optimierung der Eigenschaften von neuronalen Netzwerken in praktischen Anwendungen ein sehr komplexes Problem ist und oft viel Zeit beansprucht. Wir haben aber die Erfahrung gemacht, dass sich der entsprechende Aufwand schlussendlich immer lohnt.

XI.6 Literaturverzeichnis

- [1] J. Hertz, A. Krogh, and R.G. Palmer: *Introduction to the Theory of Neural Computation*, Addison-Wesley (1991).
- [2] L. Grolimund und H. Häutle: *Optimierung der Dotierung von ZnO-Varistoren mit Hilfe von neuronalen Netzwerken*, Diplomarbeit ETHZ, WS 1990/91.
- [3] J. Bernasconi: *Neuronale Netzwerke: Theorie und Praxis*, Bulletin SEV/VSE **82** (1991) **13**, pp. 11-16.
- [4] J. Bernasconi and F. Greuter: *Adaptive Design of Experiments*, Informatik-Informatique **1**/1998, pp. 18-20. (Siehe auch darin enthaltene Referenzen.)
- [5] Ch. Cachin: *Erkennung von Teilentladungsmustern unter Verwendung neuronaler Netzwerke*, Diplomarbeit ETHZ, WS 1992/93
- [6] Ch. Cachin and H.J. Wiesmann: *PD Recognition with Knowledge-Based Preprocessing and Neural Networks*, IEEE Trans. on Dielectrics and Electrical Insulation, Vol. 2, No. 4, August 1995, pp.578-589.
- [7] B. Buchenel et al: *Lastprognosen mit neuronalen Netzen*, Bulletin SEV/VSE **21**, 1996, pp.11-16. (Siehe auch darin enthaltene Referenzen.)