Einsatz konnektionistischer Lernmethoden für die technische Diagnose

Dipl.-Ing. Dipl.-Inform. M. Forkel
Dipl.-Ing. M. Müller
Dipl.-Ing. H. Weber

Fraunhofer-Institut für Produktionsanlagen und Konstruktionstechnik
Abteilung Arbeitsinformatik
Pascalstraße 8–9
10587 Berlin

Zusammenfassung

In diesem Beitrag werden konnektionistische Lernverfahren für die wissensbasierte Diagnose technischer Systeme vorgestellt. Es werden zwei Problemstellungen untersucht: die Prognose von Signalverläufen technischer Zustandsgrößen sowie die diagnostische Klassifikation von Systemzuständen und die Ergebnisse der Untersuchungen dargestellt.

1 Einleitung

Diagnosesysteme haben die Aufgabe, Fehlerzustände zu erkennen und Reparaturvorschläge zu erstellen, um das betroffene technische System möglichst schnell wieder in einen funktionstüchtigen Zustand überführen zu können. Dazu wird Wissen über den physikalischen Aufbau und die funktionale Struktur des technischen Systems, über Fehlersymptome und deren möglichen Ursachen, über Prüf- und Reparaturvorschläge sowie über Diagnoseverfahren benötigt. Bei den wissensbasierten Diagnosesystemen haben zwei prinzipiell unterschiedliche Verfahren Anwendung gefunden: die assoziative und die modellbasierte Diagnose. Im Rahmen unserer Forschungstätigkeiten sind beide Konzepte erprobt worden [15, 18]. Dabei hat sich gezeigt, daß eine Kombination beider Methoden sinnvoll ist, wobei der assoziative Ansatz zur schnellen Diagnose schon bekannter Fehler und der aufwendigere, modellbasierte Ansatz zur Diagnose bis dahin noch unbekannter Fehler verwendet wird.

Voraussetzung für die Anwendung der genannten wissensbasierten Diagnosemethoden ist die Akquisition des benötigten Wissens für das Einsatzgebiet. Durch den Einsatz von Techniken des maschinellen Lernens kann der Aufwand für die Wissensakquisition verringert werden. Von den vier Paradigmen des maschinellen Lernens (induktiv, analytisch, genetisch, konnektionistisch [3]) haben sich unsere Forschungsarbeiten zunächst auf analytische Verfahren konzentriert [17, 24]. Auf der Grundlage des repräsentierten Domänenmodells werden mittels erklärungsbasierter und analoger Lernverfahren Regeln gelernt und generalisiert, die zur effizienten Fehlerdiagnose verwendet werden. Diese Lernverfahren können allerdings nur bei der Existenz eines geeigneten Modells genutzt werden. Da insbesondere bei komplexen technischen Systemen der Aufbau eines solchen Modells nur mit sehr hohem Aufwand (wenn überhaupt) möglich ist, sind Lernverfahren zu erproben, die ohne diese Voraussetzung auskommen. Es bieten sich dazu konnektionistische Lernverfahren auf der Basis neuronaler Netze an.

2 Anwendungen konnektionistischer Lernverfahren für die technische Diagnose

Konnektionistische Lernverfahren werden für verschiedene Problemklassen erfolgreich eingesetzt, u.a. zur Klassifikation, als assoziative Speicher, zur Optimierung, zur Realisierung funktionaler Abbildungen, zur Prognose oder zum Ähnlichkeitsvergleich von Mustern [8, 9, 10]. Dazu sind unterschiedliche Lernverfahren wie z.B. Error-Backpropagation (EBP), Hebb, Widrow-Hoff oder Kohonen entworfen worden [2, 7, 12, 22]. Für diagnostische Anwendungen sind vornehmlich klassifizierende Netzwerke wie EBP- und selbstorganisierende Kohonen-Netzwerke von Interesse.

Der EBP-Algorithmus führt ein überwachtes Lernen in Ebenen eines geschichteten Klassifikationsnetzwerkes durch, indem er die Gewichte der als Neuronen bezeichneten elementaren Klassifikatoren durch Training mit Eingabemustern und den dazu gehörigen Ausgabemustern solange zu verbessern sucht, bis das Netzwerk die Eingabemuster auf die Ausgabemuster mit genügender Genauigkeit abbildet [13]. Bei den selbstorganisierenden Kohonen-Netzwerken werden zwischen den Neuronen Abstände und Nachbarschaften definiert, auf deren Basis ein Lernverfahren die Gewichte der Neuronen derart modifiziert, daß ähnliche Eingabemuster zur Erregung benachbarter Neuronen führen [5, 25]. Die selbstorganisierenden Netzwerke lernen unüberwacht und bilden dabei eine topologische Struktur des Eingabemusterraumes ab, die für Klassifikationszwecke genutzt werden kann.

Error-Backpropagation- und Kohonen-Netzwerke sind u.a. zur akustischen Qualitätsprüfung von Elektromotoren, zur Fehlerdiagnose an CNC-Werkzeugmaschinen und zur Fehlerdiagnose von Verbrennungskraftmotoren auf der Basis der Reibmomentanalyse eingestzt worden [1, 14, 23]. Neuronale Netze sind mit geometrischen, statistischen und Fuzzy-Klassifikationsverfahren verglichen worden und haben sich u.a. als adaptive, nichtlineare Musterklassifikatoren bewährt [6].

Das Ziel unserer Forschungsarbeiten ist die Erweiterung wissensbasierter Diagnosesysteme mit den Fähigkeiten konnektionistischer Systeme, um implizite, nichtlineare Zusammenhänge zwischen Fehlermerkmalen, insbesondere in hochdimensionalen Merkmalsräumen, zu erkennen und um Robustheit gegenüber Streuungseinflüssen bzw. Störeffekte zu erzielen. Desweiteren sollen mit Hilfe konnektionistischer Lernverfahren der Akquisitionsaufwand von Diagnosewissen verringert und eine Adaption an veränderliche Randbedingungen ermöglicht werden. Dazu wenden wir neuronale Lernverfahren bei folgenden Problemstellungen an:

- Lernen von Prognosen anhand von gemessenen Zustandsgrößen,
- Lernen von Fehlerklassifikationen anhand von prognostizierten Zustandsgrößen sowie
- die Kopplung konnektionistischer Lernverfahren mit symbolischer Wissensverarbeitung.

Zur Überwachung technischer Systeme werden deren Zustandsgrößen gemessen bzw. beobachtet. Die *Prognose der Zustandsgrößen* ermöglicht ein frühzeitiges Erkennen von Fehlern. Mit Hilfe neuronaler Netze soll aus den verrauschten Meßsignalen der weitere Signalverlauf vorhergesagt werden, damit rechtzeitig Diagnosen gestellt und Maßnahmen eingeleitet werden, die zur Vermeidung schwerwiegender Fehler führen. Dazu wird die Fähigkeit von EBP-Netzwerken genutzt, Approximationen von Funktionen lernen, die vorgegebene Zeitreihen beschreiben. Dementsprechend trainieren wir neuronale Netze mit Meßreihen der Zustandsgrößen des betrachteten technischen Systems.

Ein weiteres Anwendungsgebiet, in dem wir konnektionistische Methoden erproben, ist das *Klassifizieren von Fehlern anhand von prognostizierten Zustandsgrößen.* Neuronale Netze haben dabei den Vorteil, daß sie implizite Zusammenhänge lernen können und wesentliche Merkmale der beobachteten Muster herausstellen (Generalisierungseffekt). Sie können Korrelationen zwischen den Signalverläufen und Fehlerzuständen entdecken, die zunächst nicht bekannt sind.

Unter konnektionistischem Lernen wird die adaptive Anpassung von Gewichten und Verbindungen im neuronalen Netz verstanden. Der Lernprozeß manifestiert sich damit in einem inneren Zustand des neuronalen Netzes, der sich einer Interpretation verschließt. Um das gelernte Wissen zu nutzen und damit den Akquisitionsaufwand bei der Entwicklung wissensbasierter Systeme zu veringern, muß der innere Zustand eines neuronalen Netzes symbolisch interpretierbar sein. Mit dieser Zielsetzung wollen wir einen Lösungsansatz zur *Kopplung konnektionistischer Lernverfahren mit symbolischer Wissensverarbeitung* entwickeln, der auf dem Konzept der sogenannten wissensbasierten neuronalen Netze aufbaut [21]. Bei diesen Netzwerken repräsentieren die Knoten Bestandteile symbolischer Regeln. Der Aktionsteil einer Regel ist einem Knoten zugeordnet, der eine Anzahl von Vorgängerknoten besitzt. Die Vorgängerknoten stellen den Bedingungsteil der Regel dar, das heißt, jedem dieser Knoten wird eine entsprechende Bedingung zugeordnet. Das so entstandene neuronale Netze wird mit einem modifizierten EBP-Algorithmus trainiert. Die gelernten Regeln werden mit Hilfe des sogenannten NOFM-Algorithmus aus dem Netzwerk extrahiert [4, 19, 20]. Dieser Algorithmus faßt die Gewichte der Knoten des trainierten Netzwerks in Gruppen zusammen (Clustering), eliminiert Gruppen, die nicht zur Aktivierung eines Knoten beitragen und leitet Regeln der Form „Wenn (N der M Vorgängerknoten aktiviert) dann ...“ ab. Wissensbasierte neuronale Netze sind zum Erkennen von DNA-Sequenzen wie auch zum Lernen englischer Wörter (NETTALK) eingesetzt worden und haben dabei bessere Ergebnisse als das C4.5 System [11] erzielt, das mit Entscheidungsbäumen arbeitet. Wir beabsichtigen, diesen neuartigen Netzwerktyp zum Lernen von Diagnoseregeln einzusetzen.

3 Erfahrungen mit konnektionistischen Lernverfahren bei der technischen Diagnose

Aufgrund des Arbeitsfeldes des IPK Berlin stehen uns zur Erprobung der konnektionistischen Lernverfahren reale Anwendungsprobleme aus dem Bereich der Werkzeugmaschinen und Produktionsanlagen zur Verfügung. Um konnektionsitische Methoden anwenden zu können, wird eine ausreichende Menge von Falldaten benötigt, mit denen ein neuronales Netzwerk trainiert, getestet und bewertet werden kann. Falldaten über das Verhalten eines technischen Systems werden durch Messungen während des Betriebs ermittelt oder durch experimentelle Versuchsmessungen erzeugt, bei denen bestimmte Fehlerzustände provoziert werden.

Als Anwendungsfeld wollen wir die Diagnose von Hauptspindellagerungen vorstellen. Am IPK Berlin sind Untersuchungen über Schadensverläufe an Hauptspindellagerungen durchgeführt worden, dabei sind Schädigungsformen am Versuchsstand simuliert worden. Als Kenngrößen sind die Temperatur, der Vorspannungs- und der Laufflächenzustand des untersuchten Lagers gemessen worden. Die gemessenen Signale dienen uns als Falldaten.

Bei der *Prognose der Signalverläufe* wird der Merkmalsraum durch mehrere, äquidistant aufeinanderfolgende Werte der Kenngrößen beschrieben, die innerhalb eines betrachteten Meßintervalls liegen. Die Folge der jeweils zu prognostizierenden Werte einer Kenngröße liegen innerhalb eines sogenannten Prognoseintervalls (Abbildung 1). Zur Prognose haben wir ein kurzes Meßintervall von fünf Meßpunkten (n-4 bis n) gewählt, damit Übergänge zum Fehlverhalten schnell erkannt werden. Die Verwendung von großen Meßintervallen würde dagegen zur Trägheit der Prognose führen, da frühe Meßpunkte, die weit vor dem Übergang zum Fehlverhalten liegen, Einfluß auf die prognostizierten Werte hätten. Um vorzeitig das Fehlverhalten des Systems erkennen zu können, werden drei zukünftige Meßwerte prognostiziert. Die Prognose von mehr als drei Meßwerten erscheint nicht sinnvoll, da die Prognosegüte bei längeren Prognoseintervallen immer mehr abnimmt. Als Lernverfahren zur Prognose der Signalverläufe haben wir überwachtes Lernen mit einem EBP-Algorthmus durchgeführt. Das verwendete EBP-Netzwerk besteht aus der Eingabeschicht zur Eingabe der kodierten Meßgrößen des Meßintervalls, einer verdeckten Schicht („hidden layer“) und der Ausgabeschicht für die zu prognostizierenden Werte des Prognoseintervalls. Um die Konvergenz des Lernvorgangs zu verbessern, wurden die Lernrate und der Dämpfungsterm der Delta-Regel variiert. Wir konnten mit den konnektionistischen Lernverfahren gute Prognoseergebnisse erzielen, der relative Fehler der prognostizierten Werte lag maximal bei 8%.

Als nächster Diagnoseschritt ist aus den gemessenen und prognostizierten Meßwerten eine *Fehlerklassifikation* durchzuführen. An den Lagern sind vier Fehlerklassen untersucht worden. Der betrachtete Merkmalsraum besteht aus drei gemessenen und drei prognostizierten Werten. Als kon-

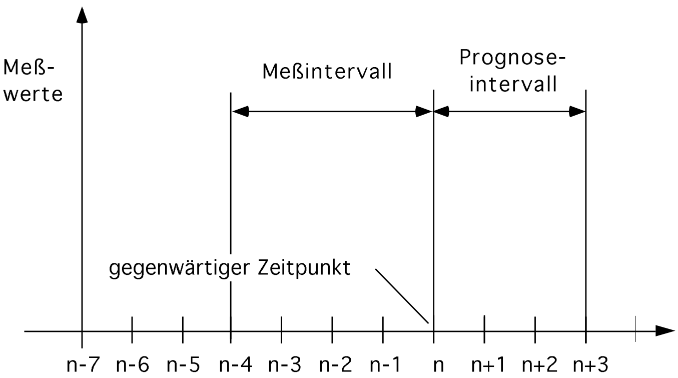

Abbildung 1: Darstellung des Zeitintervalls zur Prognose von Signalverläufen

nektionistisches Lernverfahren haben wir wiederum überwachtes Lernen mit Error-Backpropagation eingesetzt. Die Anzahl der Lerndaten betrug je 126 Daten für drei Fehlerklassen, für die vierte Fehlerklasse standen nur 10 Lerndaten zur Verfügung. Die Testmengen bestanden aus 63 bzw. 5 Datensätzen. Von den Testdaten wurden für eine Fehlerklasse maximal 7 falsch klassifiziert. Es ist vorgesehen, diese Ergebnisse mit anderen Klassifikationsverfahren zu vergleichen. In Abbildung 2 ist die Netzwerkarchitektur zur Prognose von Signalverläufen und zur Fehlerklassifikation dargestellt. Die prognostizierten Meßwerte des 1. Netzwerkes werden an die Eingänge des 2. Netzwerkes angelegt.

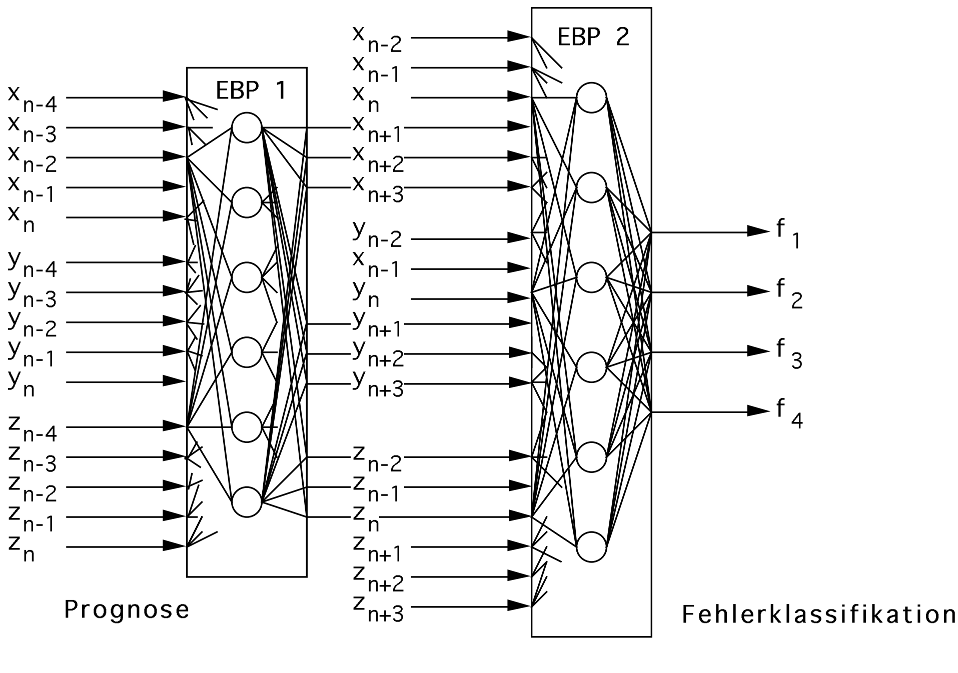

Abbildung 2: Prinzipielle Darstellung der erläuterten EBP-Netzwerkarchitektur

Unsere bisherigen Versuche, die mit dem neuronalen Netzwerksimulator NeuralWorks Professional II/Plus durchgeführt wurden, haben gezeigt, daß EBP-Netzwerke für diese diagnostischen Problemstellungen einsetzbar sind. Es wurden unterschiedliche Netzwerkgrößen ausprobiert und die Netzwerkparameter wie die Lernregel (Hebb-, Delta-, kumulative Delta-Regel u.a.), die Ausgabefunktion (Linear, Sigmoid, Sinus u.a.) oder die Lernparameter (Lernrate, Dämpfung) variiert. Ein weiterer Schritt unserer Forschungsarbeiten wird die Erprobung von wissensbasierten neuronalen Netzen zum Lernen von Diagnoseregeln sein. Da die benötigten Lernverfahren und Algorithmen in kommerziellen Netzwerksimulatoren nicht zur Verfügung stehen, werden wir eine eigene Implementation durchführen.

4 Aufbau des Diagnosesystems

Die erprobten konnektionistischen Lernverfahren sollen in ein wissensbasiertes Diagnosesystem integriert werden. Grundlage für das wissensbasierte Diagnosesystem ist das System HyperDesign, das am IPK in der objektorientierten Programmierumgebung Smalltalk entwickelt wird [16]. HyperDesign stellt zum Aufbau von Wissensbasen Repräsentationsformen wie Frames und semantische Netze zur Verfügung, zur Wissensverarbeitung wird ein vorwärtsverkettendes Regelsystem verwendet. HyperDesign verfügt außerdem über Werkzeuge zur effektiven Gestaltung graphischer Benutzungsoberflächen. Zur Erweiterung des Systems werden neuronale Netzwerke und deren Schnittstellen zur Wissensrepräsentation und -verarbeitung in Smalltalk implementiert.

Literatur

[1] Barschdorff, D.; Becker, D.: Neuronale Netze als Signal- und Musterklassifikatoren. *Technisches Messen*, 57 (1990) 11, S. 437–444.

[2] Brause, R.: *Neuronale Netze: eine Einführung in die Neuroinformatik.* Stuttgart: Teubner, 1991.

[3] Carbonell, J. G.: Introduction: Paradigms for Machine Learning. *Artificial Intelligence. Special Volume on Machine Learning*, 40 (1989), S. 1-3.

[4] Craven, M. W.; Shavlik, J. W.: Learning Symbolic Rules Using Artificial Neural Networks. In: *Machine Learning. Proceedings of the Tenth International Workshop*, S. 73-80, San Mateo, California, 1993. Morgan Kaufman Publishers.

[5] Kohonen, T.: *Self-Organisation and Associative Memory.* Berlin: Springer Verlag, 1984.

[6] Krüger, J.; Suwalski, I.: Fuzzy Logik und neuronale Netze in der Maschinendiagnose. *ZwF*, 87 (1992) 11, S. 611–615.

[7] Lau, C.; Widrow, B. (Hrsg.). *Proceedings of the IEEE. September 1990. Special Issue on Neural Networks I*, Band 78, New York, 1990. Institute of Electrical and Electronics Engineers, Inc.

[8] Maren, A.; Harston, C.; Pap, R.: *Handbook of Neural Computing Applications.* San Diego, California: Academic Press, 1990.

[9] Müller, M.: The Comparative Activation Transfer (CAT) and Temporal Pattern Learning. *WZ THI*, 37 (1991) 1, S. 75-78.

[10] N., N.: *DARPA Neural Network Study (U.S.).* Fairfax, Virginia: AFCEA International Press, 1990.

[11] Quinlan, J. R.: *C4.5: Programs for Machine Learning.* San Mateo, CA.: Morgan Kaufman Publishers, 1993.

[12] Ritter, H.; Schulten, K.; Martinetz, T.: *Neuronale Netze: eine Einführung in die Neuroinformatik selbstorganisierender Netzwerke.* Bonn, München: Addison Wesley, 1991.

[13] Rummelhart, D. E.; McClelland, J. L.: *The PDP Group: Parallel Distributed Processing. Explorations in the Microstructure of Cognition. Vol. 1: Foundations. Vol. 2: Psychological and Biological Models.* Cambridge, Mass.: The MIT Press, 1986.

[14] Scholz, C. H.: *Konzeption und Realisierung von Diagnosewerkzeugen auf der Basis konnektionistischer Modelle.* Dissertation, RWTH Aachen, 1991.

[15] Specht, D.; Wenning, V.: Einsatz eines wissensbasierten Systems zur Fehlerdiagnose. *ZwF*, 86 (1991) 11, S. 536-540.

[16] Spur, G.; Specht, D.; Forkel, M.; Weber, H.: *Wissensbasierte Unterstützung der Konzeptphase des Konstruierens.* In: Mackensen, R. (Hrsg.): *Konstruktionshandeln (in Vorbereitung)*, München: Carl Hanser Verlag. 1994.

[17] Spur, G.; Specht, D.; Weiß, S.: Integration of learning approaches for maintenance tasks. *Computer in Industry*, 17 (1991), S. 269-277.

[18] Spur, G.; Weiß, S.: Application of Model-based Diagnosis to Machine Tools. In: Gottlob, G.; Nejdl, W. (Hrsg.): *Expert Systems in Engineering. Principles and Applications. Proceedings of the International Workshop in Vienna, Austria, September 1990*, Berlin, 1990. Springer Verlag.

[19] Towell, G. G.; Craven, M. W.; Shavlik, J. W.: Constructive Induction in Knowledge-Based Neural Networks. In: Birnbaum, L. A.; Collins, G. C. (Hrsg.): *Machine Learning. Proceedings of the Eighth International Workshop*, S. 213-217, San Mateo, California, 1991. Morgan Kaufman Publishers.

[20] Towell, G. G.; Shavlik, J. W.: Extracting Refined Rules from Knowledge-Based Neural Networks. *Machine Learning*, 13 (1993) 1, S. 71-101.

[21] Towell, G. G.; Shavlik, J. W.; Noordewier, M. O.: Refinement of Approximate Domain Theories by Knowlegde-Based Neural Networks. In: *Proceedings Eighth National Conference on Artificial Intelligence*, S. 861-866, Menlo Park, 1990. The MIT Press.

[22] Vemuri, V.: *Artificial Neural Networks: Theoretical Concepts.* Computer Society Press Technology Series. Washington, D.C.: Computer Society Press of the IEEE, 1988.

[23] Verweyen-Frank, H.; Teschers, A.: Elektromotoren auf dem Prüfstand. Qualitätsprüfung und -sicherung mit künstlichen neuronalen Netzen. *ZwF*, 87 (1992) 11, S. 618–621.

[24] Weiß, S.: *Modellbasiertes Lernen zur Wissensakquisition für technische Diagnosesysteme*. München: Carl Hanser Verlag, 1993.

[25] Willshaw, D.; van der Malsburg, C.: How patterned neural connections can be set up by self-organisation. *Proc. Royal Soc. of London*, B-194 (1976), S. 431-445.

Dieser Beitrag entstand im Zusammenhang mit dem DFG-Projekt „Integration symbolisch orientierter und konnektionistisch orientierter Lernverfahren für die Diagnose“, das von Prof. Dr.-Ing. D. Specht geleitet wird.