

# Selbstorganisierende Merkmalskarten – Ein neuer Ansatz für die Produktionssteuerung

Bernd Scholz-Reiter, Steffen Müller, Tilo Hamann und Michael Freitag, BIBA Bremen

Prof. Dr.-Ing. Bernd Scholz-Reiter ist Direktor des BIBA und leitet das Fachgebiet Planung und Steuerung produktionstechnischer Systeme an der Universität Bremen. Er ist Herausgeber der Zeitschriften *Industry Management* und *PPS Management*.

Dipl.-Ing. (FH) Steffen Müller arbeitet als wissenschaftlicher Mitarbeiter am vormals von Professor Scholz-Reiter geleiteten Fraunhofer Anwendungszentrum für Logistiksystemplanung und Informationssysteme in Cottbus.

Dipl.-Ing. Tilo Hamann arbeitet als wissenschaftlicher Mitarbeiter an der Universität Bremen, Fachgebiet Planung und Steuerung produktionstechnischer Systeme.

Dipl.-Ing. Michael Freitag arbeitet als wissenschaftlicher Mitarbeiter am Fachgebiet Planung und Steuerung produktionstechnischer Systeme der Universität Bremen.

Die Komplexität von Produktions- und Logistiksystemen erzeugt den Wunsch nach robusten und fehlertoleranten Steuerungsmöglichkeiten zur Verfolgung unternehmerischer Ziele. Gerade die Produktionssteuerung und die Steuerung von Logistiksystemen sind mit den Hilfsmitteln exakter mathematischer Beschreibungen nur unzureichend zu bewerkstelligen. Einen Lösungsweg bietet die Computational Intelligence (CI) mit ihren Möglichkeiten zur symbolischen, subsymbolischen und numerischen Wissensverarbeitung. Zu dem Gebiet der Computational Intelligence zählen Verfahren der

Fuzzy-Logik, Evolutionäre Algorithmen und Künstliche Neuronale Netze (KNN). Ein Neuronales Netztyp, die selbstorganisierende Merkmalskarte (SOM), ist Gegenstand dieses Beitrags.

Künstliche Neuronale Netze sind mathematische Gleichungen, die aus vorgegebenen Eingangswerten durch ihr gelerntes Verhalten Ausgangswerte generieren können. Als positive Eigenschaften Neuronaler Netze sind ihre

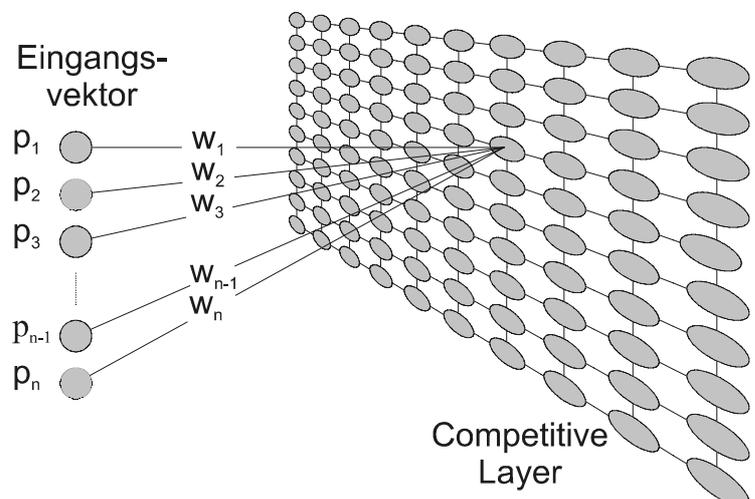
- Anpassbarkeit,
- Fehlertoleranz,
- Robustheit,
- Assoziationsfähigkeit,
- Generalisierungsfähigkeit und
- die Möglichkeit zur Abbildung von Nichtlinearitäten

zu nennen. Ihr Verhalten bilden Neuronale Netze während des Trainingszyklus aus. Als negative Eigenschaften Neuronaler Netze sind die mangelnde Analysierbarkeit (Black-Box-Verhalten) und die Abhängigkeit von der

Qualität der Trainingsdaten, die die Arbeitsqualität des Netzes beeinflussen, zu nennen. Darüber hinaus ist die Arbeitsqualität der Neuronalen Netze vom verwendeten Netztyp und hier insbesondere von der Anzahl der Neuronen, der Aktivierungsfunktion und der Anzahl der Zwischenschichten abhängig.

In einem von der Deutschen Forschungsgemeinschaft geförderten Forschungsprojekt "Modellierung und Steuerung der Produktion mit Künstlichen Neuronalen Netzen" wurden u.a. die so genannten selbstorganisierenden Merkmalskarten untersucht, da dieser Neuronale Netztyp einige für die Produktionssteuerung nützliche Eigenschaften besitzt. Zu der wohl wichtigsten Eigenschaft dieses Typs zählt, dass er zur Gruppe der nicht überwacht lernenden Neuronalen Netze gehört. Was bedeutet das? Wenn die Anzahl der zu verwendenden Neuronen, die Startlernrate, der Lernradius,

Bild 1: Architektur einer selbstorganisierenden Merkmalskarte.



Kontakt:

Fraunhofer ALI  
 Universitätsplatz 3-4  
 D-03044 Cottbus  
 Tel.: 0355 / 69-4584  
 Fax: 0355 / 69-4800  
 E-Mail: Steffen.Mueller@ali.fhg.de

der Verminderungskoeffizient der Lernrate und der Verminderungskoeffizient des Lernradius erfolgreich bestimmt wurden und sich an der Struktur und Zusammensetzung der Trainingsdaten nichts ändert, kann eine selbstorganisierende Merkmalskarte immer gebildet werden. Im Gegensatz dazu kann bei den überwachtem lernenden Neuronalen Netzen ein Lernerfolg nicht garantiert werden. Auf dem Gebiet der praktischen Anwendung Neuronaler Netze überwiegt die Verwendung überwachtem lernender Neuronaler Netze. Das liegt an der einfacheren Handhabung dieser Netztypen, an ihrem funktionsbildenden Charakter (Funktionsapproximation) und an der einfacheren Erstellung geeigneter Ein- und Ausgangsdaten.

## Selbstorganisierende Merkmalskarten (SOM)

Selbstorganisierende Merkmalskarten [1, 2], auch Kohonen Feature Map genannt, bestehen zumeist aus Neuronen die in einer 2-dimensionalen Gitterstruktur (engl. Competitive Layer) angeordnet sind. Benachbarte Neuronen sind bidirektional untereinander verbunden. Im Bild 1 ist der Aufbau einer selbstorganisierenden Merkmalskarte dargestellt. Es besteht auch die Möglichkeit 3-dimensionale Gitterstrukturen bzw. eine Reihe von Neuronen zu verwenden. Durch die Nachbarschaftsbeziehungen zwischen den Neuronen in der Gitterstruktur ist es den selbstorganisierenden Merkmalskarten möglich, n-dimensionale Datenstrukturen topologieerhaltend zu verinnerlichen. Demzufolge ist eine Klassifizierung im hochdimensionalen Datenraum, wie er im Produktions- und Logistikbereich anzutreffen ist, möglich.

Anders als bei einem vorwärts gerichteten Neuronalen Netz, gebildet mit z.B. dem Backpropagation Algorithmus, bei dem ein Ausgangsneuron verschiedene numerische Ausgangswerte kodieren kann, erfolgt bei der selbstorganisierenden Merkmalskarte die Kodierung der Ausgangswerte (Steuerinformationen für Produktion oder Logistik) über den Aktivierungs-

zustand der Neuronen in der Gitterschicht. Das Neuron mit dem größten Wert wird aktiviert. Diese wird als "Winner-Takes-It-All"-Regel bezeichnet. Selbstorganisierende Merkmalskarten erkennen die den Daten innewohnenden Ähnlichkeiten und Beziehungen. Ähnliche Daten ordnen sich "räumlich eng" ("Winner-Takes-It-All Neuron") auf der Gitterschicht an. Es bilden sich, unter dem Gesichtspunkt der Produktionssteuerung und der Steuerung von Logistiksystemen, auf der Gitterschicht Gebiete aktivierter Neuronen mit gleichen oder ähnlichen Steuerentscheidungen aus. Nach erfolgreicher Bildung einer selbstorganisierenden Merkmalskarte erfolgt die Bestimmung von Gebieten mit gleichen Steuerinformationen. Werden auf die selbstorganisierenden Merkmalskarten unbekannte, zuvor noch nicht erlernte Eingangsvektoren gegeben, so wird ein Neuron auf der Gitterstruktur aktiviert. "Fällt" das aktivierte Neuron auf ein zuvor bestimmtes Gebiet, wird eine Steuerentscheidung abgeleitet! Das Flussdiagramm im Bild 2 zeigt die verallgemeinerte Vorgehensweise bei der Bildung selbstorganisierender Merkmalskarten.

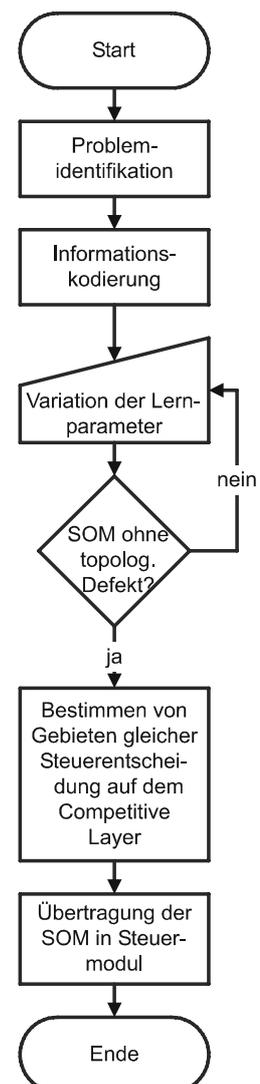
## Datenvorverarbeitung/ Informationskodierung

Ebenso wie bei dem Einsatz anderer Neuronaler Netztypen müssen auch die Daten für die selbstorganisierenden Merkmalskarten vorverarbeitet werden. Ziel dieser Datenvorverarbeitung muss es sein, die Eingabevektoren vergleichbar zu gestalten. Es lassen sich zwei Regeln für die allgemeine Datenvorverarbeitung herauskristallisieren. Das sind zum einen die Elimination von maximalen Ausreißern aus den Datensätzen und zum anderen das Normieren der Eingabevektoren auf gleiche Wertebereiche.

In [3] wird ein sehr anschauliches Beispiel für die Informationskodierung mit selbstorganisierenden Merkmalskarten dargestellt. Das Bild 3 zeigt in allgemeiner Form wie die Informationskodierung für die Eingangsvektoren zur Bildung selbstorganisierender Merkmalskarten erfolgen kann. Ein

Satz  $P_0$  von Eingangsvektoren bildet die Trainingsdaten zum Erstellen einer selbstorganisierenden Merkmalskarte. Alle Eingangsvektoren haben die gleiche Länge  $n$ . Im Aufbau des Eingangsvektors spiegelt sich die Informationskodierung wider, wobei ein Eingangsvektor aus einer kodierten Information oder aus mehreren kodierten Informationsanteilen bestehen kann. Im Bild 3 steht die Zahl eins für ein vorhandenes Merkmal und der Buchstabe  $x$  für ein nicht vorhandenes Merkmal. Für  $x$  können üblicherweise die Werte 0 oder

Bild 2: Flussdiagramm zur allgemeinen Vorgehensweise bei der Bildung selbstorganisierender Merkmalskarten.



-1 stehen. Die unterschiedlichen Informationsanteile können unterschiedlich lang sein. Ein Informationsanteil kann z.B. Daten und Kenngrößen aus dem Produktions- bzw. Logistikbereich umfassen. Ein Eingangsvektor mit seinen inhärenten Informationen verkörpert, im Sinn der Produktionssteuerung und der Steuerung von Logistiksystemen, auszuführende Maßnahmen zur Erreichung der unternehmenseigenen Ziele. Enthalten die Eingangsvektoren z.B. Informationen über die Abweichung von Lieferterminen, Auslastung der Anlagen, Kosten und aktuelle Lagermengen, so können Steuergrößen wie z.B. die Auftragsfreigabe, Kapazitätserhöhungsmaßnahmen, Instandhaltungsmaßnahmen, Personalbedarfsmeldungen und Materialanforderung usw. zugeordnet werden.

### Steuerung mit selbstorganisierenden Merkmalskarten – Ein Anwendungsbeispiel

Im Rahmen des geförderten Vorhabens wurden selbstorganisierende Merkmalskarten auf ihre Eignung für

die Produktionssteuerung hin untersucht. Stellvertretend soll auf eine Bestandsregelung im Produktionsbereich mit selbstorganisierenden Merkmalskarten eingegangen werden. Betrachtet man die Einflussgrößen, von denen der Bestand an Arbeitssystemen abhängt, so ergeben sich mindestens drei Einflussgrößen. Das sind z.B.

- die zufließende Menge an Arbeitsinhalt (welche durch die Auftragsfreigabe beeinflusst wird),
- die Verteilung des Arbeitsinhalts auf einzelne, alternativ anwählbare Arbeitssysteme im Produktionsbereich und
- die Kapazität bzw. Verfügbarkeit der Arbeitssysteme.

Somit ist eine Steuergröße, die durch die selbstorganisierende Merkmalskarte abgebildet werden soll, die Verteilung des Arbeitsinhalts auf alternativ anwählbare Arbeitssysteme. Die Steuergröße "zufließender Arbeitsinhalt/Auftragsfreigabe" wird durch eine andere Regeleinrichtung umgesetzt. Die selbstorganisierenden Merkmalskarten sind in eine Regelkreisstruktur eingebettet, ähnlich wie sie in [4, 5, 6] vor-

gestellt wurden. Eine selbstorganisierende Merkmalskarte wird einem Arbeitssystem zugeordnet.

Der Satz von Eingangsvektoren, der die in der Merkmalskarte abzubildenden Informationen enthält, umfasst Daten und Kenngrößen wie auftragsabhängige, nachfolgende Arbeitsschritt-Arbeitssystem-Kombinationen und bewertete Bestandsdifferenzen im Zusammenhang mit der Verteilung des Arbeitsinhalts als Steuergröße. Genau wie in Bild 3 besteht der Eingangsvektor aus  $m$  Informationsanteilen. Der erste Informationsanteil umfasst die Produktklasse, wobei ein Merkmal (zutreffend entspricht 1, nichtzutreffend entspricht -1) für eine Nummer steht. Die weiteren Informationsanteile stehen für die bewerteten Bestandsabweichungen nachfolgender Arbeitssysteme. Es wird ein festes Raster mit positiven und negativen Bestandsabweichungen vorgegeben. Über Variation der bewerteten Bestandsabweichungen an den verschiedenen - laut Arbeitsplan nachfolgenden - Arbeitssystemen, werden Merkmale in den Eingangsvektor eingepreßt. Bei den laut Arbeitsplan nicht zutreffenden Arbeitssystemen werden alle Merkmale, die die Bestandsabweichung beschreiben, mit -1 bewertet. Die Eingangsvektoren für die jeweiligen Steuerentscheidungen werden "vorgemerkt". Es erfolgt später eine Zuordnung der laufenden Nummern der Eingangsvektoren zu den jeweilig gleichen Steuerentscheidungen. Gebiete gleicher Entscheidungen sollen bekanntlich nach der Bildung der selbstorganisierenden Merkmalskarte entdeckt und bestimmt werden. Ein wichtiger Aspekt der bei der Erstellung von Eingangsvektoren Beachtung finden muss, ist die Tatsache, dass die Größe des Eingangsvektors nicht beliebig groß werden kann. Somit ist die Anzahl der in einer selbstorganisierenden Merkmalskarte zu klassifizierenden Informationen beschränkt.

Einen Ausweg aus diesem Dilemma zeigt die Verwendung von zwei oder mehreren selbstorganisierenden Merkmalskarten zur Informationsabbildung auf. Statt der parallelen Informationsverteilung auf mehrere Merkmalskar-

Bild 3: Allgemeine Informationskodierung für Eingangsvektoren zur Bildung selbstorganisierender Merkmalskarten.

		Steuerentscheidung						
		A	A	C		D	A	
Eingangsvektor		lfd.-Nr. Eingangsvektor	1	2	3	...	$P_{o-1}$	$P_o$
		Informationsanteil 1	Merkmal 1	$p_1$	1	x	x	...
Merkmal 2	$p_2$		x	1	x	...	x	1
Merkmal 3	$p_3$		x	x	1	...	x	x
⋮	⋮		⋮	⋮	⋮	⋮	⋮	⋮
Merkmal $IA_{1h}$	⋮		x	1	x	...	1	x
Informationsanteil 2	Merkmal 1	⋮	x	x	x	...	1	1
	Merkmal 2	⋮	1	1	x	...	x	1
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	Merkmal $IA_{2i}$	⋮	1	x	1	...	x	x
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	
Informationsanteil m	Merkmal 1	⋮	x	1	x	...	x	1
	Merkmal 2	⋮	1	x	x	...	x	x
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	Merkmal $IA_{mj-1}$	$p_{n-1}$	x	x	1	...	1	x
	Merkmal $IA_{mj}$	$p_n$	1	1	x	...	1	x

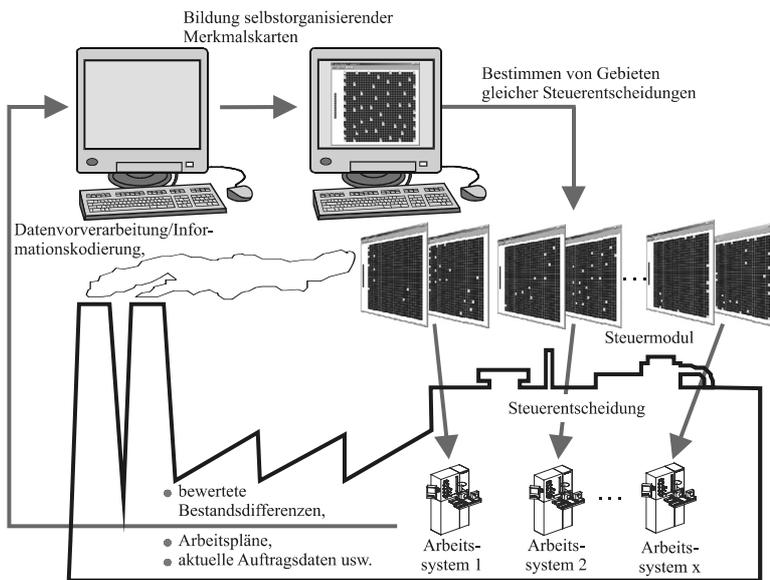


Bild 4: Informationskreis beim Einsatz Neuronaler Netze im Produktionsbereich.

ten kann auch eine zeitabhängige, fortlaufend neu gebildete Merkmalskarte zur Anwendung kommen. Informationen wie z.B. abgearbeitete Aufträge, bei denen die erlernten Auftrags-Arbeits-schritt-Beziehungen nicht mehr benötigt werden, werden aus den Eingangsvektoren entfernt und durch neue noch zu bearbeitende Auftragsinformationen ersetzt. Es werden fortlaufend neue selbstorganisierende Merkmalskarten erstellt. Das Finden von Ablöse-kriterien zur fortlaufenden Ablösung Neuronaler Netze ist Gegenstand aktueller Untersuchungen.

In Bild 4 ist der sich schließende Informationskreis schematisch dargestellt. Beginnend mit den gewonnenen Daten aus dem Produktionsbereich, der Datenvorverarbeitung/Informationskodierung, dem Training der selbstorganisierenden Merkmalskarten, dem Auffinden von Gebieten gleicher Steuerentscheidungen auf dem Competitive Layer, der Übertragung der Daten in ein Steuermodul und der Umsetzung der Steuerentscheidung schließt sich der Kreis.

Mit dem Stuttgarter Neuronale Netze Simulator (SNNS) steht ein kostenloses Werkzeug für die Arbeit und Problemlösung mit Neuronalen Netzen zur Verfügung. Die selbstorganisierenden Merkmalskarten sind einer von

vielen neuronalen Netztypen, die mit dieser Software gehandhabt werden können. Der Stuttgarter Neuronale Netze Simulator ist in guten Linux-Distributionen enthalten.

## Fazit

Die in diesem Beitrag vorgestellte Bestandsregelung mit selbstorganisierenden Merkmalskarten ist nur ein kleiner Ausschnitt für mögliche Anwendungen im Bereich der Produktionssteuerung und der Steuerung von Logistiksystemen. Die vorteilhafte Eigenschaft dieses Neuronale Netztyps - das unüberwachte Lernen - prädestiniert die selbstorganisierenden Merkmalskarten für autonom arbeitende Softwareanwendungen. Voraussetzungen für einen erfolgreichen Einsatz Neuronaler Netze ist die Schaffung von Strukturen im Produktions- und Logistikbereich, die z.B. den unterschiedlichen anzutreffenden Produktionsformen Rechnung tragen.

## Literatur

- [1] Zell, A.: Simulation Neuronaler Netze. 1. Auflage, Bonn Paris 1994.
- [2] Kohonen, T.: Self-Organization and Associative Memory. 3. Auflage, Berlin 1989.
- [3] Ritter, H.: Neuronale Netzwerke - Grundlagen und Anwendungen. In: Ritter, H. (Hrsg.): Neuronale Netze in

der industriellen Anwendung. Düsseldorf 1993.

- [4] Scholz-Reiter, B., Müller, S., Köhler, C., Freitag, M.: Durchlauf- und Bestandssteuerungskonzept für die Fertigung. In: PPS Management 6 (2001) 2, S. 14-18.
- [5] Scholz-Reiter, B., Müller, S., von Finckenstein, E.: Buffer Inventory Control in Production Systems with Neural Networks. In: CIRP GA, STC O, 2nd part, Montreux 1999.
- [6] Scholz-Reiter, B., Müller, S., Wiendahl, H.-P.: Throughput Time Control in Production Systems Supported by Neural Networks. In: Annals of CIRP Vol. 49/1, 2000, pp. 331-334.

## Schlüsselwörter:

Computational Intelligence, Künstliche Neuronale Netze, selbstorganisierende Merkmalskarten, Kohonen Feature Map, Produktionssteuerung

## Danksagung

Dieser Beitrag entstand im Rahmen des Projekts "Modellierung und Steuerung der Produktion mit Künstlichen Neuronalen Netzen", das von der Deutschen Forschungsgemeinschaft unter dem Kennzeichen Scho 540/4-3 gefördert wird.

## Self-organizing Map - A New Approach for Production Control

The complexity of production and logistics systems generates the demand for robust and error-resistant control options in the pursuit of corporate objectives. The control of production and logistics systems, especially, is often inadequately managed with methods of exact mathematical specifications alone. One solution to this problem is the use of Computational Intelligence (CI), intelligent measures for processing symbolic, sub-symbolic and numeric knowledge.

Computational Intelligence also borrows from such areas as fuzzy logic, evolutionary algorithms and artificial neural networks.

One of these neural networks types, namely the self-organizing map or Kohonen Feature Map, is the topic of this article.

## Keywords:

Computational Intelligence, neural networks, self-organizing map, Kohonen Feature Map, production control