

Modellierungsverfahren zur Optimierung und Regelung verkürzter Prozessketten

Prof. Dr.-Ing. A. Weckenmann, Dipl.-Ing. V. Bettin, Dipl.-Ing. R. Stöber, Lehrstuhl QFM, Universität Erlangen-Nürnberg

Prof. Dr.-Ing. H. Niemann, Dipl.-Inf. R. Deventer, Lehrstuhl für Mustererkennung, Universität Erlangen-Nürnberg

Gliederung

1 Einleitung

2 Modellierungsverfahren

2.1 Wissensbasierte Systeme

2.2 Neuronale Netze

2.3 Statistische Modellierung

3 Ausblick: Hybride Modellierung

4 Literatur

Abstract

Die Verkürzung der Entwicklungszeit neuer Produkte erfordert auch die Reduzierung der Entwicklungszeiten von Prozessketten zu deren Herstellung. Aus Kostengründen wird dabei eine minimale Anzahl von Prozessschritten angestrebt. Zur Beherrschung dieser Prozessketten sind neue Methoden bei der erstmaligen Einrichtung sowie Verfahren zur Regelung und Qualitätsoptimierung der bestehenden Prozessketten erforderlich.

Es wird gezeigt, welchen Beitrag Wissensbasierte Systeme, Neuronale Netze und Bayesnetze zur Modellierung leisten, wobei insbesondere die Stärken und Schwächen betrachtet werden. Anschließend wird die Anwendbarkeit der vorgestellten Modellierungsverfahren auf Spritzguss und Innenhochdruckumformen gezeigt.

1 Einleitung

Der ständig härter werdende Wettbewerb erfordert eine schnelle Umsetzung von der Idee bis zur Markteinführung neuer Produkte. Dabei spielen Faktoren wie die Entwicklungszeit der Produkte selbst, aber auch Umfang und Einrichtung der für die Fertigung notwendigen Prozessketten eine wichtige Rolle.

Im Hinblick auf eine leistungsfähige und zuverlässige Produktion sollten diese Prozessketten möglichst kurz und robust ausgelegt sein. Dieses Ziel lässt sich z. B. durch Zusammenfassen mehrerer Bearbeitungsvorgänge in einem Prozessschritt erreichen, da somit Handhabungs- und Aufspannvor-

gänge entfallen können. Diese Verfahrensintegration erschwert aber auf der anderen Seite die Ersteinstellung bei Produktionsanlauf sowie die Regelung in der Serienfertigung.

Um aktuelle Normen wie die ISO 9000ff. und Qualitätsforderungen (z. B. nach der ISO/TS 16949) einhalten zu können, werden leistungsfähige Methoden des Qualitätsmanagements benötigt, mit denen sich diese verkürzten Prozessketten mit ihrer Vielzahl von Einflussgrößen beherrschen lassen.

Besonders wichtig sind in diesem Zusammenhang speziell auf die besonderen Eigenschaften dieser verkürzten Prozessketten zugeschnittene Modellierungsverfahren, die sowohl bei der Einstellung als auch bei der Regelung von Prozessketten wertvolle Hilfestellungen leisten.

2 Modellierungsverfahren

Prozesse mit wenigen Einfluss- und Zielgrößen sind oft mit geringem Aufwand analytisch modellierbar. Die theoretischen Grundlagen für die analytische Modellbildung sind bestens erforscht und theoretisch fundiert. Diese Modelle bieten aufgrund ihrer Transparenz den Vorteil der Nachvollziehbarkeit des Lösungsweges, stoßen aber bei komplexen Prozessen bezüglich der Modellierbarkeit bzw. des dafür notwendigen Aufwands an ihre Grenzen. Dies gilt insbesondere bei Prozessketten mit vielen Einflussgrößen und Wechselwirkungen zwischen den einzelnen Prozessen (Bild 1).

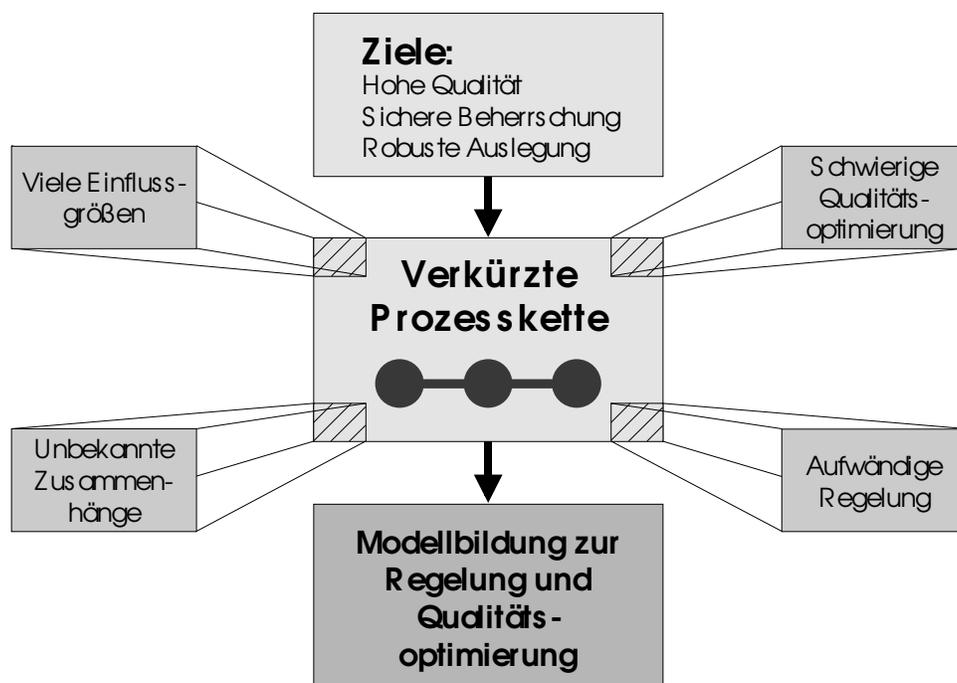


Bild 1: Problemfelder verkürzter Prozessketten

In diesen Fällen wird der Einsatz von Modellierungsverfahren erforderlich, die in der Lage sind, auf der Grundlage von wenigen Versuchsdaten die Zusammenhänge zwischen Einfluss- und Zielgrößen einer Prozesskette abzubilden. Im Rahmen der Arbeiten des von der DFG geförderten Sonderforschungsbereichs 396 „Robuste, verkürzte Prozessketten für flächige Leichtbauteile“ werden in den Teilprojekten A3, C1 und C2 Modellierungsverfahren auf der Grundlage von Neuronalen Netzen, Bayesnetzen

und Wissensbasierten Systemen für Entwicklung und Qualitätsregelung verkürzter Prozessketten erforscht.

2.1 Wissensbasierte Systeme

In Wissensbasierten Systemen können z. B. die funktionalen Zusammenhänge einer Prozesskette in Form von Regeln abgebildet werden. Als Grundlage dient das Wissen von Fachleuten, das entsprechend formalisiert in der Wissensbasis abgelegt wird. Gegenüber dem Wissen des Experten selbst, das leicht in Vergessenheit gerät, nicht beliebig vervielfältigt und nur sehr schwer weitergegeben werden kann, bieten Wissensbasierte Systeme den Vorteil, diese Kenntnisse dauerhaft verfügbar zu halten, wodurch sie gleichzeitig von einem größeren Personenkreis genutzt und auch für Schulungen eingesetzt werden können. Darüber hinaus ist bei einem Wissensbasierten System das Ergebnis der Anwendung stets reproduzierbar, wobei die Entscheidungen eines Experten aus seinem Wissensstand heraus oftmals unvorhersehbar sind.

Der Kern eines Wissensbasierten Systems besteht aus einer Wissenserwerbs-, einer Erklärungs- und einer Problemlösungskomponente [PUPPE 1993]. Die Erwerbskomponente stellt die Schnittstelle zwischen dem sogenannten Knowledge Engineer und dem System dar. Der Knowledge Engineer befragt die Experten, strukturiert ihr Wissen und implementiert es in Form von Regeln, Daten oder Relationen in der Wissensbasis. Häufig dienen hierzu erweiterte „wenn ... dann ... sonst“ - Regeln. Wenn alle Bedingungen einer Regel erfüllt sind, gilt die Hypothese als bestätigt und die mit den Bedingungen verknüpften Aktionen werden ausgeführt. Andernfalls werden die Aktionen des „sonst“-Falls aktiv. Die Ableitung der Problemlösung erfolgt über die sogenannte Inferenzmaschine, die dabei unterschiedliche Mechanismen anwendet. Der datengetriebene Ansatz (forward chaining) versucht, ausgehend von vorgegebenen Fakten, alle resultierenden Folgerungen abzuleiten. Der hypothesengetriebene Ansatz (backward chaining) überprüft ausgewählte Hypothesen auf ihre Gültigkeit. Eine Kombination beider Ansätze ist möglich. Weiterhin können Konfliktlösungsstrategien vom Knowledge Engineer durch Vergabe von Prioritäten festgelegt werden, die so zur effizienten Realisierung von Problemlösungen beitragen. Die Ergebnisse der Wissensverarbeitung werden über die Erklärungskomponente an den Benutzer ausgegeben. Diese ermöglicht aufgrund der transparenten Darstellung der verarbeiteten Regeln jederzeit das Hinterfragen der Vorgehensweise, wodurch die Nachvollziehbarkeit des Lösungswegs gegeben ist.

Die Stärken von Wissensbasierten Systemen liegen in der Darstellung komplexer Sachverhalte wie Ursache-Wirkungs-Prinzipien, „Was-ist-wenn?“ - Analysen, Randbedingungen oder Ausnahmen. Von Vorteil ist, dass sowohl quantitative, numerische Zusammenhänge (wie z. B. bekannte mathematische Beziehungen zwischen Eingangs- und Ausgangsgrößen eines Prozesses), als auch qualitative, verbale Aussagen (wie z. B. „Wenn das Kunststoffspritzgussteil verzogen ist, stimmt die Werkzeugtemperatur oder der Nachdruck nicht“), welche insbesondere bei Prozessketten häufig auftreten, in der Regelbasis abgebildet werden können.

Diese Regelbasis kann durchsucht und eine zur Zielvorgabe passende Lösung gefunden werden [WEBER 1992]. Wichtiges Kriterium hierbei ist allerdings, dass dieser Vorgang in endlicher Zeit abge-

geschlossen wird. Für den Aufbau von Qualitätsregelkreisen zur Prozesskettenbeeinflussung muss diese endliche Zeit sehr kurz angesetzt werden. Das bedeutet, dass das Regelwerk keine unnötigen Regeln enthalten darf, deren Prüfung ja auch Rechenzeit erfordert.

Ein Wissensbasiertes System erfordert bei der Erstellung hohen Aufwand. Allerdings kann es modular gestaltet werden, so dass nicht von Anfang an die komplette Prozesskette vollständig modelliert sein muss. Durch den modularen Aufbau kann auch die Übertragung auf andere Prozessketten vereinfacht werden, sofern ähnliche Fertigungsverfahren eingesetzt werden. Allerdings nimmt die Fehlerwahrscheinlichkeit zu, wenn die gestellte Aufgabe nicht mehr mit der Regelbasis übereinstimmt

Wissensbasierte Systeme erlauben über Regeln für beide Richtungen eine bidirektionale Datenverarbeitung, so dass nicht nur auf der Grundlage von Eingangsinformationen die zu erwartenden Ausgangsinformationen vorhergesagt, sondern auch nach Vorgabe der Zielwerte die einzustellenden Maschinenparameter ausgegeben werden können. Sie können zwar komplexe Verkettungen wiedergeben, sind aber nicht lernfähig.

Die Prozesskettenmodellierung erfolgt am Beispiel der Prozesskette zur Herstellung von Kunststoff-Metall-Hybridstrukturen. Diese Prozesskette ist schematisch in Bild 2 dargestellt und besteht aus insgesamt drei Prozessschritten.

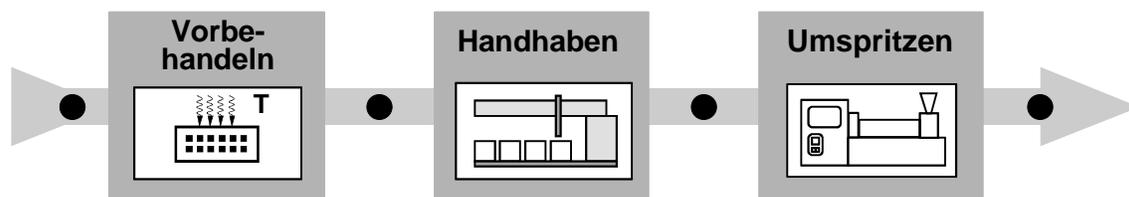


Bild 2: Prozesskette „Herstellung von Kunststoff-Metall-Hybridstrukturen“

Diese Referenzprozesskette wird in einem weiteren Teilprojekt des Sonderforschungsbereichs 396 analysiert. Im Prozessschritt „Vorbehandeln“ findet eine Vorwärmung der Metallkomponente in einem Durchlaufofen statt. Mit einem Handhabungsgerät werden die Metallteile aus dem Ausgabefach des Ofens entnommen und takt synchron mit der Spritzgießmaschine in das Spritzgießwerkzeug eingelegt („Handhaben“). Im dritten Prozessschritt „Umspritzen“ erfolgt die Fertigstellung der Hybridstruktur durch das Umspritzen des Metalleinlegeteils mit der Kunststoffkomponente.

Nach einer eingehenden Analyse der Prozesskette wurden für eine exemplarische Umsetzung anhand eines Beispielbauteils (Bild 3) einige Zielgrößen ausgewählt, nach denen die Prozesskette optimiert werden sollte:

- Verzug des Bauteils
- Gewicht
- Haftfestigkeit zwischen der Metall- und der Kunststoffkomponente
- Farb- und Glanzkennwerte der Kunststoffkomponente

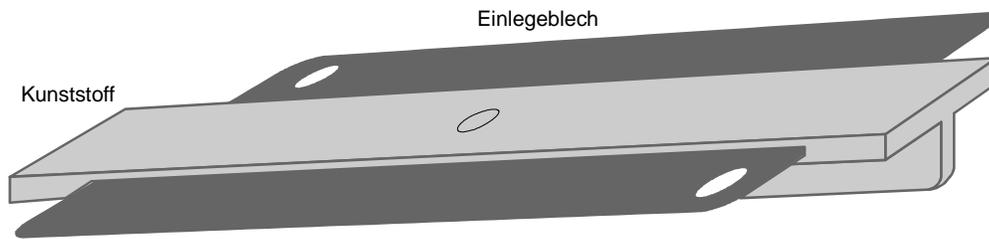


Bild 3: Beispiel eines Kunststoff-Metall-Hybridbauteils

Der Verzug stellt sich im Bauteil in Abhängigkeit der eingestellten Prozessparameter ein. Er wird einerseits durch die Rückbildung der Wärmedehnung des vorgewärmten, eingelegten und umspritzten Metallteils, andererseits durch im Kunststoff stattfindende Prozesse wie Schwindung und Nachkristallisation maßgeblich beeinflusst.

Das Gewicht des Fertigteils dient als Maß für die richtige Menge der Kunststoffkomponente, da deren Dichte durch Prozessparameter wie z. B. das eingespritzte Volumen und den dafür erforderlichen Druck beeinflusst wird.

Die Haftfestigkeit zwischen den beiden Komponenten ist ein wichtiges Kriterium für die spätere Anwendbarkeit der hergestellten Hybridstruktur. Sie wird durch die Vorwärmtemperatur des Bleches und der Temperatur der Kunststoffschmelze festgelegt.

Über die Messung der Farb- und Glanzeigenschaften der Teile sind Rückschlüsse auf die tatsächlichen Verarbeitungsparameter der Kunststoffkomponente möglich. Bei zu hoher Verarbeitungstemperatur findet eine Schädigung der Kunststoffmatrix statt, die sich unter anderem durch farbliche Veränderungen nachweisen lässt. Die Fließrichtung der Kunststoffschmelze im Spritzgießwerkzeug sowie Veränderungen der Werkzeugtemperatur lassen sich über den Glanzgrad bestimmen.

Das Wissen über die Zusammenhänge insbesondere in Bezug auf diese ausgewählten Zielgrößen wurde durch Experimente unter Anwendung von Verfahren der statistischen Versuchsmethodik untersucht. Hierbei konnten die Prozessparameter ermittelt werden, die die Zielgrößen maßgeblich beeinflussen. Insgesamt konzentrieren sich die Arbeiten auf die folgenden Prozessparameter:

- Vorwärmtemperatur des Bleches
- Massetemperatur der Kunststoffschmelze
- Werkzeugtemperatur des Spritzgießwerkzeugs
- Nachdruckhöhe und –dauer an der Spritzgießmaschine

Die Ursache-Wirkungszusammenhänge zwischen den ausgewählten Prozessparametern und den Zielgrößen wurden in dem Wissensbasierten System abgelegt. Über einen Dialog wird der Benutzer des Systems nach den Einstellwerten der Prozessparameter befragt. Nach Eingabe der Daten und Abarbeitung der hinterlegten Regeln gibt das Wissensbasierte System die voraussichtlichen Daten (Zielgrößen) des Fertigteils aus. Durch eine Erweiterung der Regelbasis ist das System darüber hinaus in der Lage, dem Benutzer die zu einer vorgegebenen Ausprägung führenden Prozessparameter zu nennen. So kann sowohl die Frage, welche Prozessparameter zu welchen Fertigteileigenschaften

führen, als auch, welche Prozessparameter eingestellt werden müssen, damit vorgegebene Zielwerte erreicht werden, beantwortet werden. Der große Vorteil der Anwendung eines Wissensbasierten Systems ist diese Bidirektionalität bei gleichzeitiger Transparenz, d. h. die Regeln, die zu dem ausgegebenen Ergebnis geführt haben, sind jederzeit einseh- und nachvollziehbar.

Für den Einsatz als Prozesskettenregelung wurde eine Oberfläche erstellt, die mit der Funktionalität des Wissensbasierten Systems hinterlegt wird (Bild 4). Über Schnittstellen ist die Kommunikation mit Sensoren und Aktoren der Prozesskette möglich.

Erfasst werden die Anfangsbedingungen (Werkstoffe, Temperaturen etc.) und alle maßgeblichen Prozessparameter, die im Hinblick auf die ausgewählten Zielgrößen signifikanten Einfluss aufweisen. Zusätzlich zu den Prozessparametern der Teilprozesse werden auch Informationen an den Schnittstellen zwischen den Teilprozessen erfasst und verarbeitet. Im Falle der Beispiel-Prozesskette betrifft dies vorwiegend die Information zu der aktuellen Temperatur des Metalleinlegeteils. Insbesondere dieser Parameter bedarf einer genauen Überwachung, da er verantwortlich für die Festigkeit des Verbundes und den Verzug des Fertigteils ist.

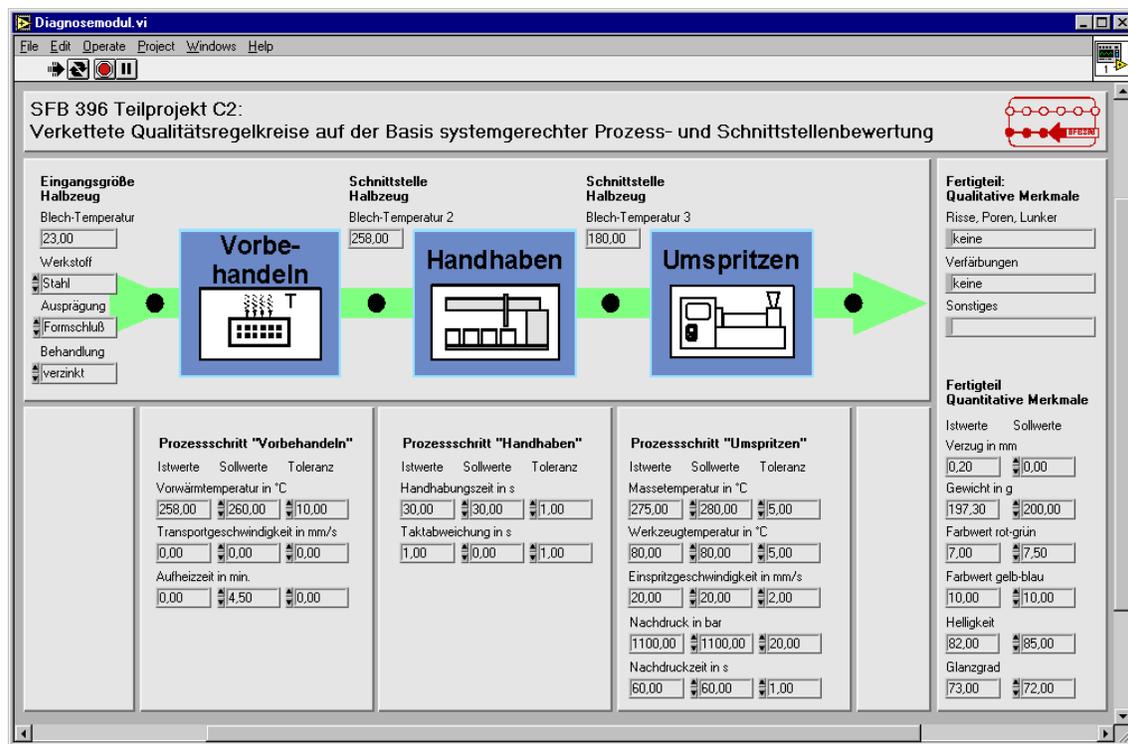


Bild 4: Bedienoberfläche für die Prozesskettenregelung

Die wichtigen Parameter in den einzelnen Prozessschritten lassen sich separat mit Sollwerten und Toleranzen vorgeben. Die aktuellen Werte der Prozessparameter werden mit diesen verglichen und aufgrund des Ergebnisses dieses Vergleichs Aktionen ausgelöst. So könnte z. B. bei einer ungenügenden Vorwärmung des Metallteils, was zu einer zu geringen Verbundfestigkeit führen würde, das betreffende Teil bereits vor dem Umspritzen aus der Fertigungslinie entfernt werden. Durch diese

präventive Regelung lassen sich die Kosten in der Prozesskette senken, da bei erkannten Abweichungen Ausschussteile gar nicht erst produziert werden. Darüber hinaus ist es möglich, bei erkannten, weniger gravierenden Abweichungen die Parameter der nachfolgenden Prozessschritte so zu modifizieren, dass die Abweichung kompensiert werden und so dennoch ein fehlerfreies Bauteil hergestellt werden kann.

Parallel zur Regelung werden die auftretenden Abweichungen erfasst, so dass Fehlerschwerpunkte innerhalb der Prozesskette bzw. deren Regelung erkannt und gezielt eliminiert werden können. Hierbei erfolgt eine Auswertung nach relativer und absoluter Häufigkeit. Auf diesem Wege wird sichergestellt, dass sich das System Prozesskette-Regelung ständig verbessern lässt.

Abschließend werden die Zielgrößen erfasst. Hier ist sowohl eine quantitative als auch eine qualitative Auswertung möglich. Damit lassen sich nicht nur zahlenmäßige Bewertungen (wie z. B. der Verzug eines Bauteils in mm), sondern auch verbale Aussagen (wie z. B. das Vorhandensein von Lunkern im Bauteil) erfassen und verarbeiten.

2.2 Neuronale Netze

Im Teilprojekt A3 werden lernfähige Qualitätsmanagementverfahren zur Einrichtung und zum Betrieb verkürzter Prozessketten untersucht. Der Schwerpunkt liegt dabei auf der Erforschung von Methoden zur Modellierung von Prozessketten mit Neuronalen Netzen. Anhand von ausgewählten Beispielprozessketten aus dem SFB 396 werden Verfahren zum Aufbau von Modellen in Abhängigkeit von der Struktur der Prozesskette aufgebaut. Eine der ausgewählten Beispielprozessketten ist die des Teilprojektes C3, die Methoden zur Verfahrensintegration von Innenhochdruckumformen (IHU) und Laserschweißen erforscht. Dazu wird die in Bild 5 auf der linken Seite dargestellte Anordnung in einer hydraulischen Presse verwendet.

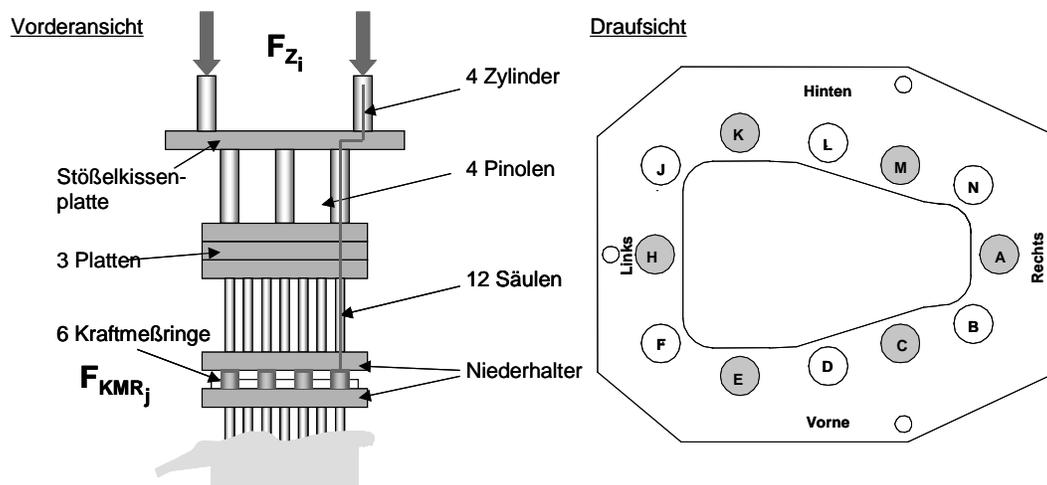


Bild 5: Innenhochdruckumformwerkzeug mit Kraftverteilung (Quelle: LFT)

Die Kraft wird über vier im Quadrat angeordnete Hydraulikzylinder auf die Stößelplatte übertragen. Dabei kann über die Pressensteuerung die Kraft jedes einzelnen Zylinders individuell eingestellt wer-

den. Von der Stößelplatte wird die Kraft auf vier Pinolen übertragen, die ihrerseits mit drei aufeinanderliegenden Stahlplatten verbunden sind. Von diesen geht der Kraftfluss auf zwölf Säulen (mit Buchstaben A .. N bezeichnet) über, die die Kraft auf die Oberseite der IHU-Form übertragen. Dabei ist es wichtig, dass in Abhängigkeit von der Geometrie des zu fertigenden IHU-Teils eine bestimmte Kraftverteilung auf der Form erreicht werden kann, damit die Bleche beim Umformen wie gewünscht eingezogen werden.

Zur schnellen Betriebspunktfindung und –optimierung ist es erforderlich, die Abhängigkeiten zwischen den eingestellten Kräften der Pressenzylinder und der Kraftverteilung auf die IHU-Form zu kennen. Dafür gibt es mehrere Möglichkeiten. Zuerst sollte überprüft werden, ob es möglich ist, eine analytische Modellierung vorzunehmen. Besonders vorteilhaft ist bei dieser Vorgehensweise die Transparenz der Modellierung und die Möglichkeit der Nachvollziehbarkeit der Rechnungen. Bei der vorliegenden Anordnung für das Innenhochdruckumformen ergibt sich allerdings die Schwierigkeit der hohen Komplexität der notwendigen Berechnungen. So ist die Aufstellung und Lösung von Matrixgleichungen mit veränderlichen Koeffizienten erforderlich, was einen unverhältnismäßig hohen Aufwand bedeutet.

Aus diesem Grund muss hier ein anderer Weg zur Modellierung beschritten werden. Dazu werden zuerst Versuche durchgeführt, bei denen an der Pressensteuerung für jeden der vier Hydraulikzylinder eine bestimmte Kraft eingestellt wird und die Kraftverteilung an der IHU-Form mit sechs Kraftmessringen bestimmt wird. Diese sind im rechten Teil von Bild 5 mit den Buchstaben A, C, E, H, K und M bezeichnet. Die Planung der Versuche wird nach den Regeln der Versuchsmethodik vorgenommen, um den Aufwand möglichst gering zu halten. Auf der Basis der so gewonnenen Versuchsdaten können anschließend mit den oben vorgestellten Verfahren Modelle erstellt werden. Mit diesen lassen sich schnell und sicher die nötigen Einstellungen der Presse für eine gewünschte Kraftverteilung finden.

Neuronale Netze sind in der Lage, Zusammenhänge zu lernen, ohne dass diese Zusammenhänge dem Anwender explizit bekannt sein müssen. Dies ist bei der Modellierung der Zusammenhänge zwischen den Kräften der Hydraulikzylinder und der Kraftverteilung der Fall. Ein Neuronales Netz ist von der Struktur her ähnlich wie das menschliche Gehirn aufgebaut. Allerdings erreichen künstliche Neuronale Netze bei weitem nicht die Komplexität und Leistungsfähigkeit des menschlichen Gehirns, weswegen hier nicht die Möglichkeiten zur Verfügung stehen, die das menschliche Gehirn bietet.

Künstliche Neuronale Netze bestehen aus einer Vielzahl von einfachen Verarbeitungseinheiten, die stark parallelisiert sind. Diese Verarbeitungseinheiten nennt man Neuronen. Sie sind zu mehreren Ebenen zusammengefasst und je nach Netztyp unterschiedlich miteinander verknüpft. Bei der Modellierung des Kraftflusses wurde ein sogenanntes Feed-Forward-Netz verwendet, das im vorliegenden Fall aus drei Ebenen, der Eingangsebene (Input layer), der inneren Ebene (Hidden layer) und der Ausgangsebene (Output layer) besteht. Bild 6 zeigt schematisch ein solches Netz. [NAUCK 1994] [HAFNER 1994]

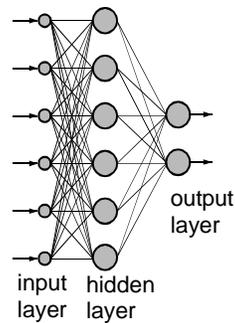


Bild 6: Schematischer Aufbau eines Neuronalen Feed-Forward-Netzes

Die Versuchsdaten aus den Messungen werden an die Eingangsebene angelegt und deren Neuronen berechnen aufgrund ihrer Anregungsfunktion eine Ausgabe. Jede dieser Ausgaben wird an jedes Neuron in der inneren Ebene weitergeleitet und dabei mit einem Gewichtungsfaktor multipliziert. Die Neuronen der inneren Ebene berechnen dann aus diesen Daten unter Verwendung ihrer Anregungsfunktion wieder eine Ausgabe, welche in gleicher Weise mit Gewichtungsfaktoren an die Ausgangsebene weitergeleitet wird. Dort berechnen dann die Neuronen mit ihrer Anregungsfunktion die Ausgaben des Netzes, die den Werten der Kraftverteilung der einzelnen Kraftmessringe an der IHU-Form entsprechen.

Die Anzahl der Neuronen in der Eingangsebene entspricht der Anzahl der Eingangsparameter. Wegen der vier verschiedenen Kräfte der Hydraulikzylinder der Presse sind bei der Modellierung vier Eingangsneuronen erforderlich. Die Anzahl der Ausgangsneuronen entspricht der Anzahl der Ausgangsparameter. So werden für die sechs Messwerte der Kraftmessringe in der IHU-Form sechs Ausgangsneuronen benötigt. Der einzig variable Parameter ist daher die Anzahl der Neuronen in der inneren Ebene, die entsprechend den Erfordernissen angepasst werden muss. Ist die Anzahl zu klein, kann das Neuronale Netz die Zusammenhänge nicht lernen, während es bei einer zu großen Anzahl nur auswendig lernt und keine Zusammenhänge speichert. In diesen beiden Fällen ist das Modell unbrauchbar. [ATLAN-TEC 1998]

Das Lernen der Zusammenhänge erfolgt bei Neuronalen Netzen über Trainingsalgorithmen. Für das Training des Neuronalen Netzes beim Kraftfluss der IHU-Anordnung wurde der sogenannte Backpropagationalgorithmus verwendet. Dabei werden die Eingangswerte an das Neuronale Netz angelegt und die Ausgaben berechnet. Diese werden anschließend mit den tatsächlichen Ausgangswerten verglichen und auf der Grundlage der ermittelten Abweichung werden die Gewichtungsfaktoren angepasst. Danach werden wieder die Eingangswerte angelegt, die Ausgaben berechnet und wieder eine Anpassung durchgeführt. Dieser Vorgang wird so lange durchgeführt, bis eine vorgegebene Abweichung unterschritten wird oder eine bestimmte Anzahl von Anpassungen überschritten ist.

Beim praktischen Training, wie bei der Modellierung des IHU-Kraftflusses sind mehrere zehntausend Anpassungsvorgänge erforderlich. Das Wissen eines Neuronalen Netzes steckt also in den Gewichtungsfaktoren. Das auf diese Weise gespeicherte Wissen hat den Nachteil, dass es schwer interpretierbar ist. Eine Aussage über den Einfluss einer bestimmten Eingangsgröße, also eines Hydraulikzylinders, auf eine bestimmte Ausgangsgröße (die Kraft an einem Kraftmessring) ist nicht ohne weiteres

zu gewinnen. Aus der schweren Interpretierbarkeit des Wissens resultiert außerdem das Problem, dass man nicht exakt weiß, welche Zusammenhänge das Neuronale Netz genau gelernt hat. Deswegen ist eine Validierung des Modells mit unabhängigen Testdaten unbedingt erforderlich. Bei der Modellierung der IHU-Kraftverteilung wurden 14 zusätzliche Testdatensätze durch Messung aufgenommen. Diese Punkte liegen zwischen den mit der Versuchsmethodik ermittelten Trainingsdatensätzen, um zu überprüfen, ob das Neuronale Netz auch wirklich die Zusammenhänge gelernt hat. Dabei sind die Abweichungen gegenüber den 14 gemessenen Werte sehr gering, wie Bild 7 entnommen werden kann. Zusätzlich zu den Ergebnissen der Modellierung mit dem Neuronalen Netz sind in Bild 7 die Vergleichswerte der Modellierung mit einem Bayesnetz angegeben.

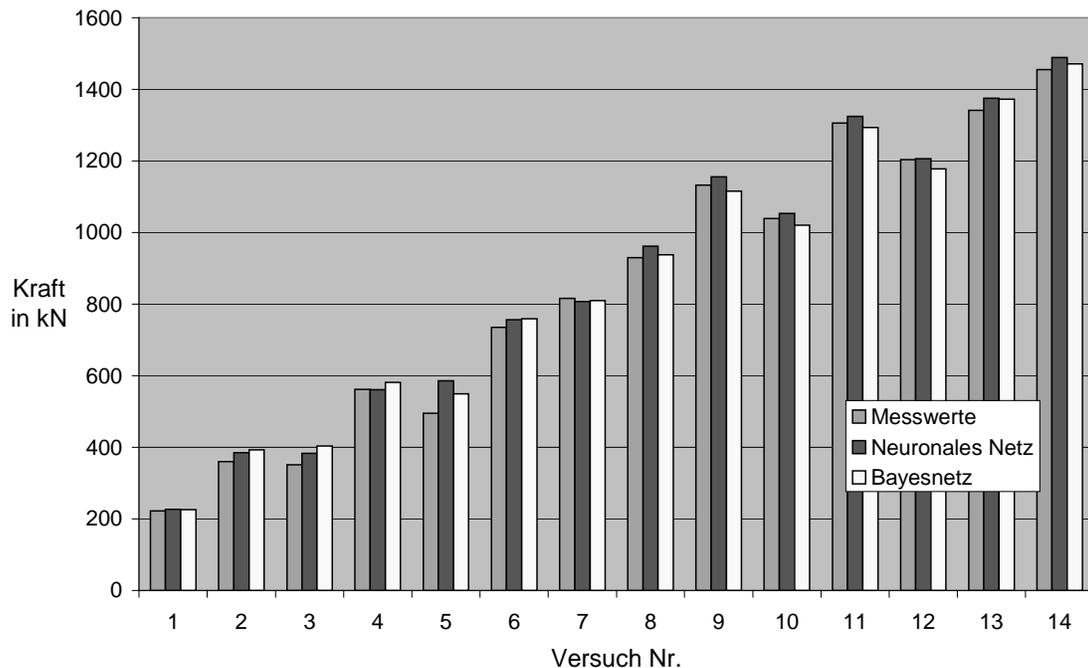


Bild 7: Gegenüberstellung von realer, mittels trainiertem Neuronalem Netz und mittels Bayesnetz vorhergesagter Gesamtkraft

Mit dem Modell auf der Basis eines Neuronalen Netzes bieten sich viele Möglichkeiten für die rasche Einstellung und Optimierung der Kraftverteilung der IHU-Form. So können genetische Algorithmen beispielsweise zu einer gewünschten Kraftverteilung der IHU-Form die erforderlichen Einstellungen der vier Hydraulikzylinder der Presse suchen. Da das Neuronale Netz die Zusammenhänge gelernt hat, ist es in der Lage, im gesamten Lernbereich gute Ergebnisse zu liefern.

2.3 Statistische Modellierung

Ziel der statistischen Modellierung im Teilprojekt C1 ist das Erlernen einer Verbundverteilung der Kenngrößen des Prozesses. Eine Verbundverteilung gibt die Wahrscheinlichkeit an, mit der gewisse Ereignisse eintreten. So kann z. B. eine Verteilung von Eingangsparametern und Qualitätsparametern

gelernt werden. Die Ein- oder Ausgabegrößen werden in Bayesnetzen durch diskrete oder kontinuierliche Zufallsvariablen repräsentiert.

Diskrete Zufallsvariable können nur endlich viele Werte annehmen, sie können z. B. zwei Schalterstellungen „an“ oder „aus“ repräsentieren. Physikalische Messgrößen, wie sie z. B. in der Fertigungstechnik auftreten, werden durch kontinuierliche Zufallsvariablen repräsentiert. Der Nachteil bei der Verwendung von Bayesnetzen, die nur kontinuierliche Variablen enthalten, ist, dass damit nur lineare Zusammenhänge dargestellt werden können. Dieser Nachteil kann durch die Verwendung hybrider Bayesnetze, die sowohl diskrete, als auch kontinuierliche Knoten enthalten, ausgeglichen werden [DEVENTER 2000/1].

Der Zusammenhang zwischen den Zufallsvariablen wird meist in einem Graphen repräsentiert, wobei die Knoten die Zufallsvariablen repräsentieren. Eine gerichtete Kante eines Knotens Y zu einem Knoten X steht meist für eine direkte Einflussnahme von Y auf X . Der Knoten Y wird dabei häufig auch als Vaterknoten von X bezeichnet. Nicht gerichtete Verbindungen oder Zyklen dürfen in einem Bayesnetz nicht auftreten, d. h. Bayesnetze werden durch einen gerichteten, azyklischen Graphen dargestellt.

Für die Verwendung von Bayesnetzen spricht die Tatsache, dass es eine große Anzahl von Lernalgorithmen gibt, die sowohl die Parameter eines Bayesnetzes [MURPHY 1998], z. B. den Mittelwert und die Streuung einer Normalverteilung, als auch die Verbindungsstruktur des Netzes lernen [COOPER 1992]. Diese Lernalgorithmen sind außerdem in der Lage mit fehlenden Daten, z. B. fehlenden Messwerten, zu arbeiten. Die graphische Darstellung erlaubt außerdem eine gute Interpretationsmöglichkeit.

Mögliche Einsatzgebiete sind z. B. die Vorhersage eines Prozessfensters (da die vorhandenen Inferenzalgorithmen in der Lage sind, von gegebenen Ausgangsvariablen auf Eingangsvariablen zu schließen [LAURITZEN 1988], [LAURITZEN 1999]), die Überprüfung eines Sensorsignals mit einem Modellwert (um einen Ausfall des Sensors vorhersagen zu können) oder Informationsgewinn durch sorgfältige Analyse des Modells, insbesondere der erkannten Unabhängigkeiten.

In diesem Artikel werden nur rein kontinuierliche Bayesnetze behandelt, da diese zur Modellierung des Kraftflusses beim Innenhochdruckumformen ausreichen.

Hierbei wird davon ausgegangen, dass alle Zufallsvariablen des Netzes normalverteilt sind. Diese Voraussetzung ergibt sich aus dem verwendeten Inferenzalgorithmus. Werden z. B. Sampling-Algorithmen verwendet, die ihre Verteilungsparameter durch ein häufiges Ziehen einer Stichprobe ermitteln, so kann auf diese Voraussetzung verzichtet werden.

Um die Güte der Modellierung mit Neuronalen Netzen und Bayesnetzen vergleichen zu können, wird auch hier die Modellierung des Kraftflusses beim Innenhochdruckumformen als Beispiel herangezogen. Hierbei wird davon ausgegangen, dass die vier Kräfte F_{Zi} die hinten links (HL), vorne links (VL) hinten rechts (HR) und vorne rechts (VR) auf die Stoßelkissenplatte wirken, unabhängig voneinander geändert werden können (Bild 5 links). Daher ergeben sich für die Struktur des Bayesnetzes keine Verbindungen zwischen den Eingabeknoten VL, HL, HR und VR. Da die Eingabezylinder zuerst auf eine Platte wirken und dann erst auf die Kraftmessringe, kann davon ausgegangen werden, dass jede Eingangsgröße einen Einfluss auf jede Ausgangsgröße hat, d. h. es ergibt sich eine Vollvernetzung

zwischen den Ein- und Ausgabeknoten. Die Ausgabeknoten dienen zur Modellierung der Kräfte F_{KMRj} auf das umzuformende Blech an den mit A, C, E, H, K und M bezeichneten Punkten (Bild 5 rechts).

Es stellt sich jetzt noch die Frage nach der Unabhängigkeit der Ausgabeknoten. Es wurden zwei verschiedene Modelle getestet, wobei in dem abgebildeten Modell Unabhängigkeit zwischen den Ausgabeknoten angenommen wurde, in einem zweiten Modell wurden noch Verbindungen zwischen den Knoten A - M aufgenommen. Die Ergebnisse wurden in einer ersten Stufe mit Crossvalidation verglichen, einem Verfahren, bei dem das Netz nur mit einem Teil der Daten trainiert wird und anschließend die Güte der Vorhersage anhand der restlichen Daten kontrolliert wird. Es zeigte sich kein nennenswerter Unterschied in der Genauigkeit zwischen den beiden Modellen, so dass für Modellierungszwecke von einer Unabhängigkeit der Ausgabeknoten ausgegangen wurde.

Damit ergibt sich die in Bild 8 dargestellte Netzwerkstruktur zur Modellierung des Kraftflusses.

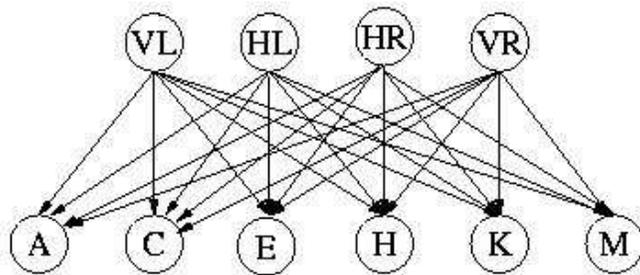


Bild 8: Modellierung des Kraftflusses

In einer zweiten Stufe wurde das Bayesnetz mit allen 69 Datensätzen trainiert. Die Modellierungsgüte wurde getestet, indem mit dem Modell für 15 Punkte Vorhersagen berechnet wurden, die nicht in den Trainingsdaten vorhanden waren. Die Ergebnisse sind in Bild 7 dargestellt. In diesem Fall zeigt sich, dass das Bayesnetz ein gutes Modell darstellt, das auch zur Generalisierung in der Lage ist. Allerdings wird bei der Verwendung von kontinuierlichen Knoten lediglich ein lineares Modell erstellt. Für die Modellierung nichtlinearer Bereiche müssen zumindest hybride Bayesnetze eingesetzt werden.

Bisher wurde mehr über die Modellierung von statischen Systemen behandelt. Ein wichtiger Faktor in der Regelungstechnik ist jedoch die Zeit. Um diesen weiteren Faktor zu betrachten, ist der Übergang zu dynamischen Bayesnetzen erforderlich. Diese ermöglichen die Modellierung zeitdiskreter, dynamischer Systeme, indem der Prozess in mehrere Zeitscheiben aufgeteilt wird, wobei jede Scheibe für sich betrachtet den Zustand eines dynamischen Systems zu einem gewissen Zeitpunkt widerspiegelt. Zusätzlich können Kanten von den Knoten der Zeitscheibe t zu den Knoten der nächsten Zeitscheibe eingefügt werden, was die Modellierung eines zeitlichen Verlaufs erlaubt. Damit lässt sich unter anderem die Regelung eines linearen, zeitvarianten Systems realisieren [DEVENTER 2000/2]. Da sich prinzipiell auch nichtlineare Systeme modellieren lassen, ist zu erwarten, dass sich auch nichtlineare Systeme regeln lassen. Die Forderung nach Zeitinvarianz ist auch nicht zwingend erforderlich, falls ein Online-Training des Systems stattfindet.

Zusammenfassend lässt sich sagen, dass Bayesnetze ein gut interpretierbares Modell liefern, deren wesentlicher Wert darin besteht, die Zusammenhänge zwischen den Ein- und Ausgabegrößen zu erlernen. Außerdem bieten sie die Möglichkeit, optimale Eingabegrößen zu ermitteln, so dass die gewünschten Ausgabegrößen mit maximaler Wahrscheinlichkeit erreicht werden. Darüber hinaus erlauben Bayesnetze nicht nur die Berechnung der Ausgabeknoten anhand der Eingabeknoten, sondern es sind auch Umkehrschlüsse möglich. Weiterhin können, ausgehend von der Struktur des Bayesnetzes, die wesentlichen Parameter erkannt werden, die einen Einfluss auf die Qualität eines Bauteils haben.

3 Ausblick: Hybride Modellbildung

Jede der vorgestellten Modellierungsmethoden hat spezifische Stärken und Schwächen. So sind Wissensbasierte Systeme nicht lernfähig, können dafür aber auch verbale Informationen verarbeiten und der eingeschlagene Lösungsweg bleibt nachvollziehbar. Bayesnetze sind lernfähig und bieten ebenfalls einen transparenten Lösungsweg. Neuronale Netze sind ebenfalls lernfähig, eignen sich besser für die Modellierung nichtlinearer Zusammenhänge, erlauben aber in der Regel kein Nachvollziehen des Lösungswegs.

Um die Nachteile der einzelnen Verfahren ausgleichen und die besonderen jeweiligen Vorteile ausnutzen zu können, bietet sich für die Modellierung verkürzter Prozessketten die Anwendung von hybriden Modellen an (Bild 9).

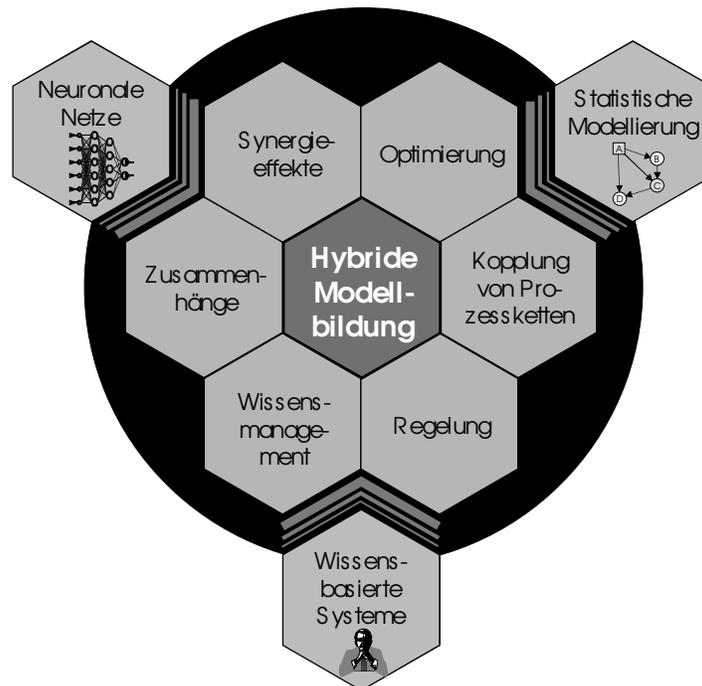


Bild 9: Bestandteile der Hybriden Modellbildung

In Zukunft wird besonderes Augenmerk auf eine hybride vernetzte Modellbildung gelegt, da sich in den bisherigen Forschungsarbeiten gezeigt hat, dass ein einziges Verfahren für die umfangreichen Herausforderungen verkürzter Prozessketten nicht ausreicht. Dabei steht insbesondere die schnelle

und einfache Modellbildung, die Möglichkeit der Selbstadaption der Modelle und erweiterte Möglichkeiten in der Regelung im Vordergrund.

Die Daten für die Modellierungen wurden uns dankenswerter Weise im Rahmen des Sonderforschungsbereichs 396 von den Lehrstühlen für Kunststofftechnik (LKT) und Fertigungstechnologie (LFT) zur Verfügung gestellt.

4 Literatur

[ATLAN-TEC 1998]

ATLAN-TEC FROESE KG: *Handbuch zu NeuroModel 1.3*. Wilich: Atlan-tec Froese KG, 1998.

[COOPER 1992]

COOPER, G. F. ; HERSKOVITS, E.: *A Bayesian Method for the Induction of Probabilistic Networks from Data*. Machine Learning 9, 303-347 (1992)

[DEVENTER 2000/1]

DEVENTER, R.; DENZLER, J.; NIEMANN, H.: *Non-linear modeling of a production process by hybrid Bayesian networks*, European Conference of Artificial Intelligence 2000, Berlin.

[DEVENTER 2000/2]

DEVENTER, R.; DENZLER, J.; NIEMANN, H.: *Control of Dynamic Systems Using Bayesian Networks; 1st Workshop on Probabilistic Reasoning in Artificial Intelligence*; Atibaia, Sao Paulo; November 2000

[HAFNER 1994]

HAFNER, S. (HRSG.): *Neuronale Netze in der Automatisierungstechnik*. München: Oldenbourg, 1994.

[LAURITZEN 1988]

LAURITZEN, S. L. ; SPIEGELHALTER D. J.: *Local Computation With Probabilities on Graphical Structure and Their Application To Expert Systems*; Journal of the Royal Statistical Society 1988 157 – 224.

[LAURITZEN 1999]

LAURITZEN, S. L.; JENSEN, F.: *Stable Local Computation with Conditional Gaussian Distributions*; Technical Report September 1999; Aalborg University, Department of Mathematical Sciences; <http://www.math.auc.dk/~steffen/publications.html>

[MURPHY 1998]

MURPHY, K. P.: *Inference and Learning in Hybrid Bayesian Networks*; Report-Nr. UCB-CSD-98-990 Computer Science Division (EECS), University of California, Berkeley, Jan. 1998 www.cs.berkeley.edu/~murphyk.

[NAUCK 1994]

NAUCK, D.; KLAWONN, F.; KRUSE, R.: *Neuronale Netze und Fuzzy-Systeme*. Braunschweig/Wiesbaden: Vieweg, 1994.

[PUPPE 1993]

PUPPE, F.: *Systematic Introduction into Expert Systems*. Berlin u.a.: Springer, 1993.

[WEBER 1992]

WEBER, F.: *Den Computer eine Art von Common Sense lehren*. Computerwoche Nr. 6 vom 07.02.1992.

Autoren:

Prof. Dr.-Ing. Albert Weckenmann, Lehrstuhl Qualitätsmanagement und Fertigungsmesstechnik,
Universität Erlangen-Nürnberg, Nägelsbachstraße 25, 91052 Erlangen,
E-Mail: weckenmann@qfm.uni-erlangen.de
WWW: <http://www.qfm.uni-erlangen.de>

Prof. Dr.-Ing. Heinrich Niemann, Lehrstuhl für Mustererkennung
Universität Erlangen-Nürnberg, Martensstr. 3, 91058 Erlangen
E-Mail: niemann@informatik.uni-erlangen.de
WWW: <http://www5.informatik.uni-erlangen.de>

Dipl.-Ing. Volker Bettin, Lehrstuhl Qualitätsmanagement und Fertigungsmesstechnik,
Universität Erlangen-Nürnberg, Nägelsbachstraße 25, 91052 Erlangen,
E-Mail: bettin@qfm.uni-erlangen.de
WWW: <http://www.qfm.uni-erlangen.de>

Dipl.-Inf. Rainer Deventer, Lehrstuhl für Mustererkennung
Universität Erlangen-Nürnberg, Martensstr. 3, 91058 Erlangen
E-Mail: deventer@informatik.uni-erlangen.de
WWW: <http://www5.informatik.uni-erlangen.de>

Dipl.-Ing. Ralf Stöber, Lehrstuhl Qualitätsmanagement und Fertigungsmesstechnik,
Universität Erlangen-Nürnberg, Nägelsbachstraße 25, 91052 Erlangen,
E-Mail: stoeber@qfm.uni-erlangen.de
WWW: <http://www.qfm.uni-erlangen.de>