

## Generierung heuristischer Modelle zur Diagnose

Benno Stein und Uwe Husemeyer  
{stein,uhu}@upb.de  
FB 17, Praktische Informatik  
Universität Paderborn, 33095 Paderborn

### Kurzfassung

Dieser Beitrag stellt ein Verfahren vor, um aus komplexen Verhaltensbeschreibungen eines technischen Systems ein effizientes Diagnosemodell zu generieren.

## 1 Diagnose technischer Systeme

Ausgangspunkt der Betrachtungen ist ein modular aufgebautes technisches System  $S$ . Für die Komponenten von  $S$  stehen Verhaltensmodelle  $M_1, \dots, M_n$  zur Verfügung, mit denen das Verhalten von  $S$  in der gewünschten Genauigkeit darstellbar ist – d. h.: Setzt man die Komponentenmodelle entsprechend der Topologie von  $S$  zusammen, so erhält man ein Modell  $\mathcal{M}$  von  $S$ , mit dem sich physikalische Größen von  $S$  simulieren lassen. In diesem Zusammenhang bezeichnet man  $\mathcal{M}$  auch als ein Modell des korrekten (O.K.-) Verhaltens von  $S$ . “Auffällige” Abweichungen zwischen dem durch die Simulation von  $\mathcal{M}$  vorhergesagten und dem an  $S$  beobachteten Verhalten heißen *Symptome*. Ein *Diagnosekandidat* ist eine oft einelementige Menge von Komponenten, die – im defekten Zustand – alle beobachteten Symptome in  $S$  hervorrufen können.<sup>1</sup> Eine als defekt bestätigte Komponente heißt *Fehler* oder *Diagnose*. Ziel des diagnostischen Prozesses ist die Identifikation von Fehlern in  $S$ .

Die computerbasierte Diagnose von technischen Systemen hat eine lange Tradition, und es sind eine Reihe von Verfahren zur teilweisen bzw. vollständigen Automatisierung der Diagnose entwickelt worden. Ein wichtiges Unterscheidungsmerkmal aus Sicht der Informatik basiert auf der Einteilung in modellbasierte und heuristische Diagnoseverfahren. Modellbasierte Diagnose bedeutet die Suche nach einem Verhaltensmodell  $\mathcal{M}_d$ , dessen Simulation mit allen Beobachtungen am realen System verträglich ist. Heuristische Diagnose entspricht einer Klassifikation auf der Basis einfacher Assoziationen der Form: “Wenn Symptom  $s$  beobachtet wird, so liegt Fehler  $d$  vor”. Die modellbasierte Diagnose beruht auf der Verhaltenssimulation von  $S$  und ist in der Regel aufwendig; sie kann als eine universelle Methode angesehen werden, die sich im Prinzip immer dann einsetzen läßt, wenn sich das Verhalten des zu diagnostizierenden Systems durch eine Simulation von geeignet verschalteten Komponentenmodellen nachbilden läßt.<sup>2</sup> Die heuristische Diagnose beruht

<sup>1</sup>Allgemein gesehen können Fehler im Prozeß (Defekte in der Konstruktion, Antriebsfehler, Sensorfehler, äußere Hindernisse) und in der Steuerelektronik auftreten [1].

<sup>2</sup>Modellbasierte Diagnose wird auch als “diagnosis from first principles” bezeichnet [2].

auf Erfahrungswissen von Experten; liegt dieses Wissen in expliziter Form vor, so ist sie wesentlich einfacher als der modellbasierte Ansatz zu operationalisieren.

Aus Sicht der Automatisierungstechnik wird zwischen Diagnosesystemen unterschieden, die off-line oder on-line arbeiten [3]. On-Line-Diagnosesysteme sind direkt mit dem zu diagnostizierenden System bzw. dem darauf ablaufenden Prozeß gekoppelt; sie können die Daten ausnutzen, die zum Messen, Steuern, Regeln und Überwachen der Anlage zur Verfügung stehen. Auch hierbei geht es um einen Vergleich der Prozeßdaten mit entsprechenden korrekten Referenzwerten; eine ermittelte Differenz wird in diesem Zusammenhang als *Residuum* bezeichnet [1]. Für eine Fehlerfrüherkennung in  $S$  ist die Realisierung eines On-Line-Diagnosesystems unumgänglich. Die Berechnung der Referenzwerte erfolgt in der Regel analytisch modellgestützt, entweder durch eine Parameterschätzung oder durch eine Zustandsschätzung [4]. Die Parameterschätzung geschieht mittels eines Eingangs-Ausgangs-Modells von  $S$  zusammen mit einer ausreichenden Zahl von Stichproben; die Zustandsschätzung geschieht mittels eines Beobachters. Auf Basis der berechneten Residuen wird mit Schwellwertverfahren, Mustererkennung oder Filtern entschieden, ob tatsächlich ein Symptom vorliegt. Die Rückführung von Symptomen auf ihre Ursache (= Fehler), also der eigentliche Diagnoseprozeß, geschieht off-line. Er läßt sich, wie eingangs beschrieben, modellbasiert oder heuristisch realisieren.

**Einordnung des Diagnoseansatzes** Die in diesem Papier vorgestellte Generierung heuristischer Modelle zielt auf die Symptomerkennung und den Off-Line-Diagnoseprozeß. Ausgangspunkt ist die Beobachtung, daß der heuristische Diagnoseansatz sowohl robust ist als auch eine hohe Fehlererkennungsquote zu leisten vermag – vorausgesetzt, daß ausreichend Erfahrung bezüglich des Systems  $S$  vorliegt. Jedoch ist die Akquisition dieses Wissens aufwendig, mit vielen Fehlerquellen verbunden oder eventuell gar nicht möglich, wie z. B. bei neuen Anlagen.

Eine interessante Möglichkeit zur Wissensakquisition ist die Durchführung von Simulationen, bei denen bestimmte Komponenten als fehlerhaft angenommen werden. Vereinfachend gesagt, im Sinne einer Modellkompilation können viele Fehlerszenarien durchgespielt und bezüglich Auffälligkeiten analysiert werden. Ziel ist die Kodierung von Zusammenhängen über Symptome und Fehler in Form eines heuristischen Regelmodells. Von der Logik der Inferenz ähnelt diese Vorgehensweise einer direkten Schätzung physikalischer Komponentenparameter; der Inferenzprozeß ist jedoch off-line und geschieht auf Basis simulierter Werte. Deshalb ist neben der Kenntnis des O.K.-Verhaltens  $\mathcal{M}$  eines Systems  $S$  auch Wissen über die möglichen Fehler in Form von analytischen Fehlermodellen für defekte Komponenten erforderlich. Die Erstellung eines heuristischen Diagnosemodells ist eine Optimierungsaufgabe: Eine gegebene Menge  $D$  von Fehlern ist mit möglichst geringem Meßaufwand zu klassifizieren – oder: Für gegebene Mengen von Meßpunkten und Fehlern ist der Klassifikationsfehler zu minimieren.

Der hier vorgestellte Ansatz ist für Anlagen in der Hydraulik zugeschnitten und getestet worden, kann aber auch für andere modulare Systeme spezialisiert werden. Der Ansatz unterstützt insbesondere Diagnosesituationen, in denen ein On-Line-Diagnosesystem aus technischen oder Kostengründen nicht realisierbar ist. Er kann jedoch auch, als nach-

geschalteter Inferenzmechanismus, Teil eines On-Line-Diagnosesystems bilden. In diesem Fall kann das Wissen über die Meßstellenauswahl direkt bei der Synthese eines Zustandsbeobachters einfließen.

## 2 Generierung eines heuristischen Diagnosemodells

Grundlage zur Erzeugung eines Diagnosemodells  $\mathcal{C}_R$  ist eine Simulationsdatenbasis  $\mathcal{C}$ . Sie entsteht auf Basis eines Modells  $\mathcal{M}$  des korrekten Verhaltens von  $S$  und einer Menge von Komponentenfehlermodellen  $M_{d_1}, \dots, M_{d_m}$  für die Fehler  $D = \{d_1, \dots, d_m\}$ . Aus  $\mathcal{C}$  werden in verschiedenen Abstraktions- und Fokussierungsschritten hinsichtlich Symptomerkennung, Intervallbildung, Meßstellenauswahl und Regelerzeugung immer kleinere Wissensbasen  $\mathcal{C}_\Delta, \mathcal{C}_I, \mathcal{C}_O$  und schließlich  $\mathcal{C}_R$  berechnet. Die nachfolgenden Abschnitte skizzieren die Verarbeitungsschritte; Tabelle 1 zeigt eine Übersicht.

Verarbeitungsschritt $\Rightarrow$ Datenbasis	Aufbau der Vektoren in der Datenbasis			
	Phase	Eingang	Verhalten	Fehler
Simulation $\Rightarrow \mathcal{C}$	$(\pi,$	$\mathbf{u},$	$z_1, \dots, z_n,$	$d, \varepsilon_d)$
Symptomerkennung $\Rightarrow \mathcal{C}_\Delta$	$(\pi,$	$\mathbf{u},$	$\delta_1, \dots, \delta_n,$	$d)$
Intervallbildung $\Rightarrow \mathcal{C}_I$	$(\pi,$	$\mathbf{u},$	$\iota_1, \dots, \iota_n,$	$d)$
Meßstellenauswahl $\Rightarrow \mathcal{C}_O$	$(\pi,$	$\mathbf{u},$	$\iota_{o_1}, \dots, \iota_{o_k},$	$d)$
Regelerzeugung $\Rightarrow \mathcal{C}_R$	$(\pi,$	$u_{r_1} \wedge \dots \wedge u_{r_k} \wedge \iota_{r_1} \wedge \dots \wedge \iota_{r_m} \rightarrow d)$		

**Tabelle 1:** Generierung eines heuristischen Diagnosemodell  $\mathcal{C}_R$  aus der Simulationsdatenbasis  $\mathcal{C}$ .

**Simulation** Die hier betrachteten Systeme  $S$  sind elektro-hydraulische Anlagen mit mehreren funktionalen Einheiten (Achsen), die einen Fertigungsprozeß oder eine Manipulationsaufgabe realisieren. Ein Modell  $\mathcal{M}$  von  $S$  enthält zeitkontinuierliche Beschreibungen und Ereignis-Constraints; die Verarbeitung geschieht mit differential-algebraischen Verfahren, die um Methoden zur Ereignisbehandlung erweitert wurden. Der Prozeß, der durch eine hydraulische Anlage realisiert und auf Basis von  $\mathcal{M}$  simuliert wird, entspricht einer Abfolge von Phasen (Eilgang, Druckhalten, Positionieren, etc.). Der Wechsel von einer Phase in eine andere wird durch ein Zustandsereignis (z. B. Zylinderanschlag, Druckbegrenzungsventil) oder ein Zeitereignis (Wegeventil) ausgelöst [5]. Aus Sicht der Diagnose und der Lernbarkeit von Diagnoseregeln sind insbesondere die stationären Werte in den Phasen interessant.

Das Ergebnis des Simulationsschritts ist eine Datenbasis  $\mathcal{C}$ . Sie enthält Vektoren, die aus Simulationen von  $\mathcal{M}$  und  $\mathcal{M}_d$  für prozeßtypische Eingänge  $\mathbf{u}$  hervorgegangen sind und für jede Phase  $\pi$  des Prozesses die stationären Werte  $z_1, \dots, z_n$  der physikalischen Größen zusammenfassen (Zeile 1 in Tabelle 1). Dabei bezeichne  $\mathcal{M}_d$  ein Modell von  $S$ , bei dem ein korrektes Komponentenmodell durch ein Modell mit dem Fehler  $d$  ersetzt worden ist. Beispielhaft für die verschiedenen Komponentenfehlermodelle an Schaltventilen, Wegeventilen, Zylindern oder Antrieben stellt folgende Tabelle das Widerstandsverhalten eines kor-

rekten und eines defekten Rückschlagventils gegenüber; der Abweichungskoeffizient  $\varepsilon_{\text{valve}}$  ist eine komponentenspezifische Zufallsvariable.

Korrektes Widerstandsverhalten	Fehlerhaftes Widerstandsverhalten
$R = \frac{m^2 \cdot \Delta p}{(\Delta p - p_0)^2}$	$R = \frac{m^2 \cdot \Delta p}{(\Delta p - p_0 \cdot (1 + \varepsilon_{\text{valve}}))^2}$

**Symptomerkennung** Im Rahmen der Symptomerkennung werden die physikalischen Größen, die aus Simulationen des korrekten Modells  $\mathcal{M}$  resultieren, mit Simulationen der fehlerhaften Modelle  $\mathcal{M}_d$  verglichen. Die Symptomerkennung basiert auf einem Differenzoperator  $\ominus$ , der zu je zwei Vektoren aus  $\mathcal{C}$  einen Symptomvektor mit den Elementen  $\delta$  berechnet (Zeile 2 in Tabelle 1). Der Operator  $\ominus$  unterscheidet zwischen “Effort”- und “Flow”-Größen<sup>3</sup>: Bei Effort-Größen wie auch bei gleich gerichteten Flow-Größen wird eine numerische Differenz gebildet; die Differenz ungleich gerichteter Flow-Größen wird qualitativ charakterisiert. Das Ergebnis der Anwendung von  $\ominus$  auf die Vektoren in  $\mathcal{C}$  ist die Symptomdatenbasis  $\mathcal{C}_\Delta$ .

**Intervallbildung** Die Intervallbildung dient zur Generalisierung der numerischen Symptome in  $\mathcal{C}_\Delta$  und stellt eine Optimierungsaufgabe dar: Der Informationsverlust hinsichtlich der Fehlerdiskriminierung (Klassifikation) ist zu minimieren; dabei sind die technischen Randbedingungen der realen Meßgeräte sowie Anforderungen aus der Praxis (Ablesegenauigkeiten, glatte Intervallgrenzen) zu berücksichtigen. Das von uns realisierte Verfahren zählt zu der Klasse der globalen, überwachten Diskretisierungsalgorithmen [7, 8]. Die Abstraktion durch die Intervallbildung bedeutet auch, daß der Bereich der realen Zahlen verlassen und für jede Größe  $z$  durch den symbolischen Bereich  $I_z$  ersetzt wird, in dem jedem numerischen Intervall  $\delta$  eindeutig ein Name  $\iota \in I_z$  zugeordnet ist (Zeile 3 in Tabelle 1).

**Meßstellenauswahl** Tatsächlich kann aus technischen oder Kostengründen in  $S$  oft nur ein Bruchteil aller physikalischen Größen gemessen werden, und somit ist die Dimension des Symptomraums in der Praxis viel kleiner als  $|\mathcal{c}|$ ,  $c \in \mathcal{C}, \mathcal{C}_\Delta$  oder  $\mathcal{C}_I$ . Aufgabe der Meßstellenauswahl ist die Bestimmung derjenigen meßbaren Größen in  $\mathcal{M}$ , die den maximalen Informationsgewinn bezüglich der Fehlerdiskriminierung liefern. Hier fließen statistische Überlegungen (Korrelationsanalyse, A-Priori-Wahrscheinlichkeiten), informationstheoretische Maße (ideelle Informationsentropie) und Konzepte aus der Theorie der Diagnose (Überdeckung von Konfliktmengen) ein [9, 10, 11, 12].

Aufgrund der multivariaten Regelerzeugung kann sich die Abhängigkeitsanalyse auf den bivariaten Fall beschränken; sie basiert auf dem Korrelationskoeffizient nach Pearson und reduziert die Anzahl der für eine Messung in Frage kommenden Parameter auf etwa die Hälfte. Die entscheidende Reduktion der Dimension des Symptomraums geschieht durch eine Schätzung des Meßaufwands: Für jede physikalische Größe  $z$  wird berechnet, inwieweit Wissen über  $z$  die Anzahl der noch erforderlichen Messungen einschränkt. Sei  $\kappa(z, \iota) \subseteq D$  die Menge der Fehler, die sich an der Meßgröße  $z$  mit einer Abweichung im Intervall  $\iota$  bemerkbar machen. Unterstellt man eine Gleichverteilung der Fehler in der Intervallmenge  $I_z$

<sup>3</sup>Diese Bezeichnung sind in der Bondgraphen-Methodologie üblich [6].

der Meßgröße  $z$ ,<sup>4</sup> so kann  $|\kappa(z, \iota)| / \sum_{\tau \in I_z} |\kappa(z, \tau)|$  als Schätzer für die Wahrscheinlichkeit genommen werden, daß Symptom “ $(z, \iota)$ ” auftritt. Insbesondere läßt sich der Diskriminierungsaufwand für Fehler aus  $D$  bei Messung von  $z$  (also der Informationsgehalt von  $z$ ) wie folgt quantifizieren:

$$e(z) = \sum_{\iota \in I_z} \frac{|\kappa(z, \iota)|}{\sum_{\tau \in I_z} |\kappa(z, \tau)|} \cdot \log_r |\kappa(z, \iota)| \quad \text{mit} \quad r = |I_z|.$$

Die Projektion von  $\mathcal{C}_I$  auf die Größen mit dem höchsten Informationsgehalt führt zur Datenbasis  $\mathcal{C}_O$  (Zeile 4 in Tabelle 1).

**Regelerzeugung** Das Ziel des Regelerzeugungsschritts ist die Extraktion zuverlässiger und aussagekräftiger Regeln aus der Datenbasis  $\mathcal{C}_O$  in Form von heuristischen Symptom-Fehler-Beziehungen (Zeile 5 in Tabelle 1). Ihre Semantik ist durch die aussagenlogischen Bewertungsfunktionen  $\alpha : \bigcup I_z \rightarrow \{0, 1\}$  und  $\beta : D \rightarrow \{0, 1\}$  und die Datenbasis  $\mathcal{C}_O$  (als Universum) bestimmt:

$$\alpha(\iota) = \begin{cases} 1, & \text{falls } \delta_z \text{ in } \iota \\ 0 & \text{sonst} \end{cases} \quad \beta(d) = \begin{cases} 1, & \text{falls } d \text{ der Komponentenfehler ist} \\ 0 & \text{sonst} \end{cases}$$

Die meisten der über  $\mathcal{C}_O$  konstruierbaren Diagnoseregeln  $\mathbf{r}$  sind bezüglich des logischen Folgerungsbegriffs inkonsistent. Trotzdem enthalten sie wertvolles (heuristisches) Wissen, dessen Unsicherheit bzw. Relevanz mit der *Konfidenz*  $c(\mathbf{r}) = h(\mathbf{r})/h(\mathbf{r}^-)$  und dem *Support*  $s(\mathbf{r}) = h(\mathbf{r})/|\mathcal{C}_O|$  bewertbar ist;  $h(\mathbf{r})$  bezeichne die relative Häufigkeit von  $\mathbf{r}$  in  $\mathcal{C}_O$ ,  $\mathbf{r}^-$  bezeichne die Prämisse der Regel  $\mathbf{r}$ .

Die Anzahl der aus  $\mathcal{C}_O$  konstruierbaren Diagnoseregeln wächst exponentiell mit der Regellänge. Deshalb kommen Data-Mining-Verfahren aus dem Bereich der Assoziationsregelerzeugung zum Einsatz, um die zuverlässigsten Symptom-Fehler-Kombinationen aus  $\mathcal{C}_O$  zu filtern [13, 8]. Diese Regeln besitzen eine Mindestkonfidenz, einen Mindestsupport und werden nicht subsumiert. Das Ergebnis des Mining-Prozesses ist ein anlagenspezifisches heuristisches Regelmodell  $\mathcal{C}_R$ .

### 3 Modellanwendung


Die Verarbeitung der Regeln in  $\mathcal{C}_R$  ist der Inferenzschritt des Diagnoseprozesses; er besteht aus der Ermittlung der in einer Diagnosesituation anwendbaren Regeln auf der Basis von  $\alpha$  und der Verrechnung dieser Regeln zur Ableitung einer Fehlervorhersage. Im Gegensatz zu anderen Konfidenzverrechnungen (wie z. B. in MYCIN [14]) sind hier alle Symptomkombinationen und damit alle anwendbaren Regeln bekannt. Das wird im folgenden Verrechnungsschema für die Konfidenz  $c(d)$  eines Fehlers  $d \in D$  berücksichtigt:

$$c(d) := c(\beta(d) = 1) = c(\mathbf{r}^*) + (1 - c(\mathbf{r}^*)) \cdot \frac{1}{|\mathcal{R}|} \sum_{\mathbf{r} \in \mathcal{R}} c(\mathbf{r}),$$

$\mathcal{R} \subseteq \mathcal{C}_R$  bezeichne die Menge der anwendbaren Regeln mit Konklusion  $d$ ,  $\mathbf{r}^* \in \mathcal{R}$  bezeichne eine Regel mit der höchsten Konfidenz.

<sup>4</sup>Diese Formel läßt sich hinsichtlich gegebener A-Priori-Wahrscheinlichkeiten anpassen [12].

**Ergebnisse** Eine Operationalisierung des Ansatzes und Tests mit mittelgroßen hydraulischen Anlagen (ca. 50 Komponenten,  $|D| \approx 15$ ) liefern vielversprechende Ergebnisse. Der Anwender beschreibt graphisch in FluidSIM [15] das Modell des zu diagnostizierenden Systems und definiert die maximale Anzahl von Meßgeräten sowie deren Auflösung; aus diesen Angaben wird gemäß den Schritten von Tabelle 1 das Diagnosemodell  $\mathcal{C}_R$  generiert. Die folgenden Diagramme geben einen Ausschnitt der Ergebnisse wieder. In Abhängigkeit von der Anzahl ausgewählter Meßgeräte ist links für unterschiedliche Mindestkonfidenzen die Anzahl erzeugter Diagnoseregeln und rechts der Anteil korrekter Fehlervorhersagen dargestellt.



## Literatur

- [1] Frank, P. M.: Diagnoseverfahren in der Automatisierungstechnik. at 42 (1994), S. 47-64.
- [2] Reiter, R.: A Theory of Diagnosis from First Principles. AI 32 (1987), S. 352-371.
- [3] Isermann, R.: Wissensbasierte Fehlerdiagnose technischer Prozesse. at 11 (1988), S. 421-426.
- [4] Mosterman, P. J.; Biswas, G.; Manders, E. J.: A Comprehensive Framework for Model Based Diagnosis: Theory and Practice. 9th Int. Workshop on Principles of Diagnosis (1998).
- [5] Otter, M.: Objektorientierte Modellierung mechatronischer Systeme am Beispiel geregelter Roboter. Düsseldorf: VDI-Verlag, 1995.
- [6] Cellier, F. E.: Continuous System Modeling. New York: Springer-Verlag, 1991.
- [7] Dougherty, J.; Kohavi, R.; Sahami, M.: Supervised and Unsupervised Discretization of Continuous Features. 12th International Conference on Machine Learning (1995), S. 194-202.
- [8] Husemeyer, U.: Heuristische Diagnose mit Assoziationsregeln. Diss. Univ. Paderborn, 2001.
- [9] Hartung, J.: Statistik. München: Oldenbourg, 1999.
- [10] Forbus, K. D.; de Kleer, J.: Building Problem Solvers. Cambridge: MIT Press, 1993.
- [11] de Kleer, J.; Williams, B. C.: Reasoning about Multiple Faults. AR (1986), S. 132-139.
- [12] Stein, B.: Model Construction in Analysis and Synthesis Tasks. Habilitationsschrift (eingereicht), Univ. Paderborn, 2001.
- [13] Agrawal, R.; Imielinski, T.; Swami, A.: Mining Association Rules between Sets of Items in Large Databases. ACM SIGMOD International Conference on Management of Data (1993).
- [14] Buchanan, B.; Shortliffe, E.: Rule-Based Expert Systems. Massachusetts: Addison-W., 1984.
- [15] Stein, B.; Curatolo, D.; Hoffmann, M.: Simulation in FluidSIM. SiWis '98 (1998).