

Ähnlichkeit in PATDEX

Klaus-Dieter Althoff & Stefan Weiß
Universität Kaiserslautern, Fachbereich Informatik
Arbeitsgruppe Künstliche Intelligenz - Expertensysteme
(Prof. Dr. Michael M. Richter)
email: (althoff, wess)@informatik.uni-kl.de

1. Einführung

PATDEX ist ein fallbasiertes Diagnosesystem, das sowohl selbständig als auch im Rahmen einer Wissensakquisitionswerkbank zur Diagnose technischer Systeme (MOLTKE: Althoff, 1992a; Althoff, Maurer et al., 1992) eingesetzt werden kann. Es besteht aus zwei eigenständigen Teilkomponenten zur Klassifikation und zur Testauswahl. Zentraler Inferenzmechanismus für beide Komponenten ist *fallbasiertes Schließen*, d.h. PATDEX lernt analytische Begriffsbeschreibungen auf der Basis von Diagnosefällen. Grundlegend hierfür ist die Interpretation der Ähnlichkeit zwischen Fällen mit Hilfe von Ähnlichkeitsmaßen. Die Berechnung und Aktualisierung der Ähnlichkeitsbewertung erfolgt dabei nach einem effizienten Verfahren, das auf einer dynamischen Partitionierung der Fallbasis beruht. Obwohl hierbei nur für einen Teil der Fälle ein neuer Ähnlichkeitswert berechnet wird, findet das Verfahren trotzdem alle "sehr ähnlichen" Fälle. Darüber hinaus garantiert PATDEX die richtige Klassifikation aller einmal eingegebenen Fälle.

Im Falle der Klassifikationsaufgabe ist das Ähnlichkeitsmaß vollständig dynamisch, d.h. die zugrunde liegende Bewertungsfunktion wird mit Hilfe eines konnektionistischen Lernverfahrens (Wettbewerbslernen) an das beobachtete Expertenverhalten angepaßt. Für die Testauswahl erfolgt eine Anpassung aufgrund einer Schätzung der mittleren Diagnosekosten mit Hilfe eines A*-ähnlichen Verfahrens. PATDEX ist stabil hinsichtlich der Verarbeitung redundanter, unvollständiger sowie inkorrektur Fälle und berücksichtigt unsicheres Wissen in Form von Defaultwerten für Symptome. In der Werkbank repräsentiertes Wissen kann von PATDEX als Hintergrundwissen verwendet werden (z.B. zum Identifizieren abnormer und/oder relevanter bzw. zum Ableiten weiterer Symptomwerte).

PATDEX geht von einer gewichteten linearen Bewertungsfunktion als Ähnlichkeitsmaß aus (vgl. Def. 1). Zu seiner Berechnung erfolgt eine Einteilung der Symptomwerte in verschiedene Kategorien, was einer (dynamischen) Gewichtung der entsprechenden Symptome dient. Die Zuordnung eines Symptoms zu einer Kategorie basiert auf dem Vergleich zwischen der Fallbasis und der aktuell gegebenen, unvollständig beschriebenen Fehlersituation. Die folgenden Überlegungen sind dabei maßgebend für die Festlegung der Symptomkategorien (vgl. Tab 1):

- Bei der Bewertung einer Situation sollen sowohl positive als auch negative Aspekte berücksichtigt werden.
- Die positiven Aspekte einer Situation sollen für die positive Bewertung der Ähnlichkeit die negativen Aspekte überwiegen.
- Ein nicht erfülltes Symptom bedeutet nicht, daß der aktuelle Fall zur Erklärung der Fehlersituation ungeeignet ist.
- "Falsche" Symptomwerte stellen einen sehr negativen Aspekt bei der Bewertung dar.
- Unbekannte Symptome werden als potentiell erfüllte Symptome angesehen (ein optimistisches Diagnoseverhalten).
- Symptome, die im aktuellen Fall nicht enthalten sind, sollen zur Beurteilung der Ähnlichkeit zwar herangezogen, aber nicht überbewertet werden.

Symptomkategorie	Beschreibung	Gewichtung
Kategorie der unbekanntenen Symptomwerte \mathbf{U}_1	Das Symptom wurde in der aktuellen Diagnosesituation noch nicht erhoben (wohl aber im aktuell betrachteten Diagnosefall)	γ
Kategorie der erfüllten Symptomwerte \mathbf{E}	Das Symptom wurde erhoben und trifft auf die aktuelle Fehlersituation zu	α
Kategorie der falschen Symptomwerte \mathbf{F}	Das Symptom wurde erhoben und trifft auf die aktuelle Fehlersituation nicht zu	β
Kategorie der nicht enthaltenen Symptomwerte \mathbf{U}_2	Das Symptom wurde erhoben und trifft auf die aktuelle Fehlersituation zu, ist aber im aktuell betrachteten Diagnosefall nicht enthalten	δ

Tab.1 - Symptomkategorien zur Unterstützung des Ähnlichkeitsmaßes

Der maximale Wert des Ähnlichkeitsmaßes soll ein festes $N \mid N$ sein, er entspricht der *identischen* Situation. Hingegen liegt der unterste Wert des Ähnlichkeitsmaßes unterhalb von $-N$. Er entspricht der Situation, in der alle Symptome den falschen Wert haben, d.h. der Fall gilt als *widerlegt*. Gemäß der obigen Forderungen können wir folgende qualitativen Eigenschaften der Parameter α, β, γ und δ festhalten: $|\beta| > |\alpha| > |\gamma, \delta|$ bzw. $\alpha > 0$ und $\beta, \gamma, \delta < 0$. Wir haben bislang also, in Abhängigkeit von den Parametern α, β, γ und δ eine Klasse von Ähnlichkeitsmaßen definiert, die abstrakt gesehen die Anforderungen erfüllen könnten (vgl. Def. 1). Hier soll uns das vorerst genügen. Wie die Werte des Ähnlichkeitsmaßes μ nun möglichst effizient berechnet werden können, ist Gegenstand des nächsten Abschnittes.

Definition 1: Ähnlichkeitsmaß μ

Seien C ein beliebiger Diagnosefall, Sit eine beliebige Fehlersituation, "card" die Mengenkardinalität, α, β, γ und δ reelle Zahlen mit den obigen Eigenschaften sowie $\mathbf{E}, \mathbf{F}, \mathbf{U}_1$ und \mathbf{U}_2 die Symptomkategorien aus Tab. 1. Die allgemeine (statische) Form des Ähnlichkeitsmaßes μ stellt sich dann wie folgt dar: $\mu(C, Sit) := \frac{\mathbf{a} \cdot card(\mathbf{E}) + \mathbf{b} \cdot card(\mathbf{F}) + \mathbf{g} \cdot card(\mathbf{U}_1) + \mathbf{d} \cdot card(\mathbf{U}_2)}{card(\mathbf{E} \cup \mathbf{F} \cup \mathbf{U}_1 \cup \mathbf{U}_2)} \in [\mathbf{b}; \mathbf{a}]$

2. Diagnosefälle

Diagnosefälle sind der zentrale Repräsentationsformalismus des PATDEX-Systems. Aus Sicht der PATDEX-Architektur können sie (vereinfacht) als 4-Tupel mit $C = (Sit, \varepsilon, \sigma, D)$ verstanden werden. Dabei gilt:

- Sit die Beschreibung einer Fehlersituation
- ε die Eingangsevidenz mit $0 = \varepsilon < 1$

- σ die Diagnoseschwelle mit $\varepsilon < \sigma = 1$
- D ist die zum Fall C gehörige Diagnose

Sit beschreibt dabei die konkrete Situation, in der ein Servicetechniker die Diagnose D gestellt hat. Die Parameter σ und ε haben für den Diagnoseprozeß folgende Bedeutung:

- Ein Fall C wird als mögliche Lösung für das aktuelle Diagnoseproblem in Betracht gezogen, falls $\mu(C, \text{Sit}) = \varepsilon$ gilt
- Die im Fall C vermerkte Diagnose darf von PATDEX gestellt werden, falls $\mu(C, \text{Sit}) = \sigma$ gilt.

Den Schwellwert ε können wir dabei als einen Wert verstehen, ab dem ein Fall C als zu einer vorgegebenen Situation als wahrscheinlich ähnlich betrachtet wird, so daß die Erhebung weiterer Symptome des Falles C sinnvoll ist. Der Schwellwert σ stellt ein hinreichendes Kriterium für die Ähnlichkeit zwischen Fall und Situation dar, das sinnvollerweise in Abhängigkeit von der Diagnose D bestimmt wird. Verursacht eine Diagnose D, falls sie irrtümlich gestellt wurde, geringe Kosten, so kann der Schwellwert σ relativ niedrig angesetzt werden. Werden durch eine Fehldiagnose D jedoch sehr hohe Kosten verursacht, so ist σ entsprechend hoch zu wählen. Ein Beispiel für niedrige Folgekosten ist die Diagnose *Sicherung defekt*, die sehr leicht überprüft werden kann. Im Gegensatz dazu verursacht eine Fehldiagnose *Antriebslager defekt* sehr hohe Kosten, da eine Überprüfung sehr aufwendig ist. In diesem Fall sollte σ sehr hoch gewählt werden. Im Extremfall $\sigma=N$ wird eine exakte Übereinstimmung von Fall und vorliegender Situation gefordert.

3. Effiziente Berechnung des Ähnlichkeitsmaßes

Auf Basis der lokal für jeden Fall definierten Schwellwerte σ und ε und der oben eingeführten Symptomkategorien wird jeder Fall C bezüglich seiner Ähnlichkeit zur aktuell beschriebenen Fehlersituation $\phi := \mu(C, \text{Sit})$ und gewisser Zusatzinformationen (alle Symptome des Falles C erhoben, Ablehnung durch den Benutzer) in folgende Kategorien eingeteilt:

- Kategorie der *widerlegten* Fälle
Fälle, bei denen alle Symptomwerte falsch sind.
- Kategorie der *abgelehnten* Fälle
Fälle, wo alle Symptome erhoben wurden und trotzdem $\phi < \sigma$ gilt bzw. Fälle, die vom Benutzer explizit abgelehnt wurden.
- Kategorie der *ununterscheidbaren* Fälle
Fälle mit $\phi = 1$, d.h. die Situation des Falles und die aktuelle Situation sind identisch.
- Kategorie der *hinreichend ähnlichen* Fälle
Fälle mit $\sigma < \phi < 1$, d.h. die Diagnoseschwelle wurde überschritten.
- Kategorie der *wahrscheinlich ähnlichen* Fälle
Fälle mit $\varepsilon = \phi = \sigma$, d.h. die Eingangsevidenz wurde überschritten, die Diagnoseschwelle allerdings noch nicht.
- Kategorie der *minimal ähnlichen* Fälle
Fälle mit $0 = \phi < \varepsilon$, d.h. es sprechen nicht mehr Fakten gegen den Fall als für ihn.
- Kategorie der *unähnlichen* Fälle
Fälle mit $\phi < 0$, d.h. es sprechen mehr Fakten gegen den Fall als für ihn.

Ohne die beiden oberen Kategorien, die auf den Zusatzinformationen basieren, lassen sich die Kategorien auch als Ähnlichkeitskategorien interpretieren.

Ähnlich wie beim Ähnlichkeitsmaß zuvor, haben wir es auch hier wieder mit einer Klasse von Kategorien in Abhängigkeit von verschiedenen Parametern zu tun (ε , σ). Die hier auftretenden

Parameter sind aber von einer anderen Art, da sie lokal für jeden Fall ("persönlich") zu definieren sind. Für eine effiziente Berechnung des Ähnlichkeitsmaßes bilden nun gerade die Kategorien aus Tab. 1 den Ausgangspunkt. Sie definieren gewissermaßen eine Art "Ähnlichkeitsstatus".

Für eine gegebene Anfangssituation wird die Fallbasis in aktivierte und nichtaktivierte Fälle partitioniert. Ein Fall heißt dabei *aktiviert*, wenn mindestens eines der in ihm enthaltenen Symptome einen Wert ungleich unbekannt hat. Da der Ähnlichkeitswert nichtaktivierter Fälle auf jeden Fall echt negativ ist, liefert die Menge der nichtaktivierten Fälle eine Approximation der Menge der unähnlichen Fälle. Als Kandidaten für ähnliche Fälle berücksichtigt PATDEX lediglich aktivierte Fälle, die in eine *Kandidatenliste* eingetragen werden. Für sie wird dann das zugehörige Ähnlichkeitsmaß berechnet und eine Zuordnung zu den jeweiligen Kategorien aus Tab. 1 vorgenommen. Letztere induzieren eine bestimmte Reihenfolge bei der Betrachtung potentieller Kandidatenmengen, die als Aktivierungshierarchie der entsprechenden Fallmengen verstanden werden kann. Die Motivation für diese Vorgehensweise ist, möglichst wenig Fälle gleichzeitig betrachten zu müssen.

In die Kandidatenliste aufgenommen werden die Fälle der höchstmöglichen Ähnlichkeitskategorie. Sobald die aktuelle Situation verändert wird, wird die Kandidatenliste aktualisiert. Dies wird sehr effizient gestaltet. Der zugrunde liegende Algorithmus erhält als Eingabe das *Falgedächtnis* und den neuen Symptomwert. Als Ausgabe liefert er die Menge derjenigen Fälle, die durch die Symptomwertänderungen ihren Ähnlichkeitswert verbessern konnten, einschließlich der (Neu-)Berechnung ihres Ähnlichkeitsmaßes (basierend auf der Aktualisierung der Mächtigkeiten der jeweiligen, fallabhängigen Symptomkategorien).

4. Aktualisierung der Ähnlichkeit zwischen Fällen und Fehlersituation

Das zugrunde liegende Verfahren zur Bewertung und Aktualisierung der einzelnen Fallähnlichkeiten zur aktuell beschriebenen Fehlersituation gestaltet sich wie folgt:

- Die Basis bildet ein vierstufiges Abhängigkeitsnetz, wobei es sich stets um beidseitige Abhängigkeiten handelt:
 - *Stufe 1:* Symptomklassen (z.B. *Ventil*)
 - *Stufe 2:* Symptome (z.B. *Ventil5Y1*)
 - *Stufe 3:* atomare Diagnoseformeln (z.B. *Ventil5Y1 = 'geschaltet'*)
 - *Stufe 4:* Diagnosefälle, deren zugrunde liegende Fehlersituation über atomare Diagnoseformeln beschrieben wird [z.B. (*SLV010; I/O-Karte defekt'; (Maschinenfehlermeldung = '159', I/O-StatusOut24 = 'logisch 1')*)].

Für jeden eingegebenen Symptomwert können unmittelbar alle betroffenen Fälle angegeben werden. Die Eingabe neuer bzw. das Ändern bereits bekannter Symptomwerte ist somit sehr effizient durchführbar.

- Nach Eingabe einer initialen Beschreibung der gegebenen Fehlersituation wird für alle aktivierten Fälle das Ähnlichkeitsmaß berechnet. Für jeden aktivierten Fall werden hierzu seine Symptome in eine der vier Symptomkategorien eingetragen.
- In Abhängigkeit von der jeweils ermittelten Ähnlichkeit werden die Fälle in die entsprechenden Ähnlichkeitskategorien eingeordnet. Widerlegte bzw. abgelehnte Fälle werden nicht weiter verfolgt (dies wird dem Benutzer mitgeteilt).
- Die Fälle der höchsten Ähnlichkeitskategorie werden in die Kandidatenliste eingetragen.
- Wird ein weiteres Symptom erhoben, so ändert sich dessen Symptomwert. Alle hiervon abhängigen Diagnoseformeln werden neu ausgewertet.

- Von den neu ausgewerteten Formeln abhängige Fälle erhöhen, je nach der in ihnen enthaltenen Situation, die Anzahl ihrer erfüllten bzw. ihrer falschen Symptomwerte und verringern die Anzahl ihrer unbeantworteten Symptomwerte.
 - Bei erfülltem Symptomwert wird geprüft, ob der Fall bewiesen wurde bzw. ob er in die Kandidatenliste aufgenommen werden kann.
 - Bei falschem Symptomwert wird geprüft, ob der Fall widerlegt oder abgelehnt wurde bzw. ob er aus der Kandidatenliste entfernt werden muß.
- Von den neu ausgewerteten Formeln unabhängige Fälle der aktuellen Kandidatenliste inkrementieren die Anzahl der von ihnen nicht erklärbaren, d.h. die nicht in ihnen enthaltenen, Symptomwerte.
- Für alle Diagnosefälle der Kandidatenliste wird das Ähnlichkeitsmaß neu berechnet.

Erwähnenswert ist dabei die Tatsache, daß trotz der Einschränkung der Neuberechnung des Ähnlichkeitsmaßes auf Fälle innerhalb der Kandidatenliste garantiert werden kann, daß "ähnlichste" Fälle auch gefunden werden, da ja bei der Neuberechnung alle Diagnosefälle berücksichtigt werden, die ihren Ähnlichkeitswert verbessern.

5. Erweiterungen

Das bislang beschriebene Verfahren wird ergänzt durch eine Berücksichtigung der Ähnlichkeit zwischen einzelnen Symptomwerten (eines Symptoms). Darüber hinaus werden die Symptome gemäß ihrer Relevanz für eine bestimmte Diagnose gewichtet. Die Relevanzen selbst werden als Teil des zu lernenden Erfahrungswissens aufgefaßt. Die Gewichtung von Symptomen wird vom System im Laufe der Zeit, oder in einer optionalen Trainingsphase mit einem Experten, selbst ermittelt. Für die Relevanz eines Symptoms ist es dabei von Bedeutung, ob ein Symptom auch Ausdruck eines normalen Systemverhaltens sein kann, z.B. "Relais 21k3 angezogen", oder ob es einen ausgesprochen pathologischen Charakter, wie z.B. "Spannung 214 zu hoch", besitzt.

Über die Berücksichtigung von Symptom-Diagnose-Relevanzen sowie pathologische Symptomwerten hinaus, bietet PATDEX die Möglichkeit, zusätzliches Hintergrundwissen einzusetzen. Dabei wird die Beschreibung der aktuellen Fehlersituation erweitert, indem zusätzliche Symptomwerte abgeleitet werden, entweder durch spezifizierte Defaultwerte oder kausale bzw. heuristische Ableitungsregeln. Im Rahmen der MOLTKE-Werkbank können die Ableitungsregeln durch GenRule bzw. iMake (vgl. Althoff, 1992b; Schuch, 1992) automatisch generiert werden.

Für eine genauere Beschreibung von PATDEX sowie die Behandlung spezieller Aspekte sei auf die nachfolgende Literaturliste verwiesen (Kapitel 6).

6. Literatur

- Althoff, K.-D. (1992a). Eine fallbasierte Lernkomponente als integrierter Bestandteil der MOLTKE-Werkbank zur Diagnose technischer Systeme. *Dissertation*, Universität Kaiserslautern
- Althoff, K.-D. (1992b). Lernen von abkürzungsorientiertem diagnostischen Problemlösen. Erscheint in: K. Reiss, M. Reiss & H. Spandl (Hrsg.), *Maschinelles Lernen*, Springer Verlag (in Vorbereitung)
- Althoff, K.-D. (1992c). Machine Learning and Knowledge Acquisition in a Computational Architecture for Fault Diagnosis in Engineering Systems. Erscheint in: *Proc. International Machine Learning Conference, Workshop on "Computational Architectures for Supporting Machine Learning and Knowledge Acquisition" in Aberdeen*

- Althoff, K.-D., De la Ossa, A., Maurer, F., Stadler, M. & Weiß, S. (1989). Adaptive Learning in the Domain of Technical Diagnosis. *Proc. Workshop on Adaptive Learning*, FAW Ulm
- Althoff, K.-D., Kockskämper, S., Maurer, F., Stadler, M. & Weiß, S. (1989). Ein System zur fallbasierten Wissensverarbeitung in technischen Diagnosesituationen. In: Retti, J. & Leidlmeier, K. (Hrsg.) (1989), *5. Österreichische Artificial-Intelligence-Tagung*, 65-70, Springer Verlag
- Althoff, K.-D., Maurer, F., Traphöner, R. & Weiß, S. (1991). Die Lernkomponente der MOLTKE₃-Werkbank zur Diagnose technischer Systeme. *KI*, 5, Nr. 1, Baden-Baden: FBO-Verlag, 58-64
- Althoff, K.-D., Maurer, F., Traphöner, R. & Weiß, S. (1992). MOLTKE - An Integrated Workbench for Fault Diagnosis in Engineering Systems. *Proc. EXPERSYS-92, Paris*
- Althoff, K.-D. & Weiß, S. (1991). Case-Based Knowledge Acquisition, Learning and Problem Solving in Diagnostic Real World Tasks. *Proc. EKAW-91, Glasgow & Crieff*
- Koks, G. (1992). Entwicklung einer Testumgebung zur Bewertung der Integrationsmöglichkeiten von GenRule, PATDEX und der MOLTKE-Shell. *Diplomarbeit*, Universität Kaiserslautern (in Vorbereitung)
- Richter, M. M. (1992). Classification and Learning of Similarity Measures. Erscheint in: Proc. der 16. Jahrestagung der Gesellschaft für Klassifikation e.V., Springer Verlag
- Richter, M. M. & Weiß, S. (1991). Similarity, Uncertainty and Case-Based Reasoning in PATDEX. *Automated Reasoning - Essays in Honor of Woody Bledsoe*, 249-266, Kluwer Academic Publishers
- Schuch, A. (1992). iMAKE - Inkrementelle Modellierung und Simulation technischer Geräte zur Generierung einer Wissensbasis für MOLTKE. *SEKI Working Paper SWP-92-05*
- Weiß, S. (1991). PATDEX/2: ein System zum adaptiven, fallfokussierenden Lernen in technischen Diagnosesituationen. *SEKI Working Paper SWP-91-01*