

# Modelle für die Generierung von Folgesitzungen zur Therapieüberwachung in fallbasierten Trainingssystemen

Alexander Hörnlein, Joachim Baumeister, Frank Puppe

Universität Würzburg, Lehrstuhl für Künstliche Intelligenz und Angewandte Informatik

Email: {hoernlein, baumeister, puppe}@informatik.uni-wuerzburg.de

## Zusammenfassung

In diesem Papier wollen wir verschiedene Formalismen zur Modellierung von Therapie- und Diagnoseeffekten vorstellen und zeigen, wie die damit beschriebenen Effekte in d3web.Train<sup>1</sup>, einem intelligenten fallbasierten Trainingssystem ([Hoer02]), verwendet werden können, um Folgesitzungen zu generieren. Eine medizinische Sitzung in d3web.Train endet mit der Angabe der Therapien, die aufgrund der erkannten Diagnosen angewandt werden sollen. Folgesitzungen sind dann Sitzungen, die den Lernenden mit den Auswirkungen der von ihm gewählten Therapien konfrontieren und ihm die Möglichkeit bieten, diese Auswahl neu zu überdenken.

Dazu werden wir einen zunächst ausdruckschwachen Formalismus inkrementell so erweitern, dass die mit diesem Formalismus generierbaren Folgesitzungen immer realistischer werden. Dabei gehen wir darauf ein, welches die Vor- und Nachteile der verschiedenen Formalismen sind und wie sich das einmal eingegebene Wissen in späteren Iterationen wiederverwenden lässt.

## 1 Motivation

Fallbezogenes Lernen in der Medizin soll es dem Studenten ermöglichen, medizinische Sachverhalte in einen Kontext eingebettet zu lernen. Durch das Erkennen und Behandeln einer kompletten realistischen Symptomatik können Wechselwirkungen zwischen verschiedenen Erkrankungen und Behandlungen vermittelt werden. Nicht zuletzt kann auch die ökonomische und soziale Kompetenz des Lernenden gesteigert werden, indem ihm die Kosten einer Untersuchung und deren Risiken für den Patienten rückgemeldet werden. Dieser Anspruch wird auch an fallbasierte computergestützte Trainingssysteme (CBT) gestellt. Eine Sitzung im fallbasierten Training lässt sich (wie in Abb. 1 dargestellt) folgendermaßen unterteilen:

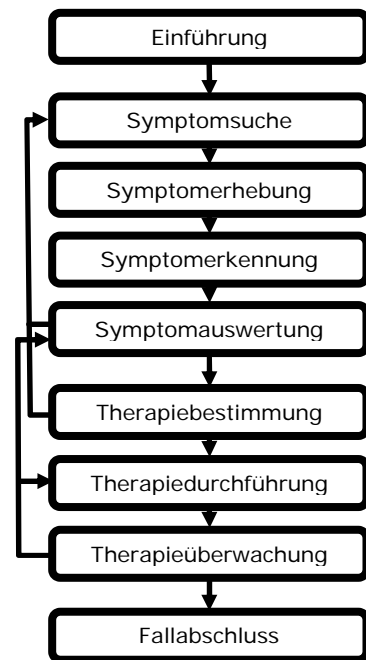
- **Einführung:** Der Lernende erhält eine informelle Darstellung der Gesamt-Situation mit einer ersten Vorstellung des Patienten.
- **Symptomsuche:** Der Lernende muss entscheiden, welchen Symptomen er seine Aufmerksamkeit widmen will und welche Tests er durchführen oder anfordern will.
- **Symptomerhebung:** Die gewählte Untersuchung wird vom Lernenden durchgeführt. Bei CBT ist dies eigentlich nicht möglich, Virtual-Reality-Szenarios mögen hier einen gewissen, letztlich aber nicht ausreichenden Ersatz bieten.
- **Symptomerkennung:** Die Ergebnisse der Untersuchungen werden ausgewertet. Hier können CBT den realen Patienten fast vollständig ersetzen, wenn für alle pathologischen Befunde ausreichend geeignete Multimedia-Daten zur Verfügung stehen.
- **Symptomauswertung:** Der Lernende muss aufgrund der bisher von ihm festgestellten Symptomatik diagnostizieren, welche Erkrankung bei dem Patienten vorliegt.

---

<sup>1</sup> Die Arbeiten wurden vom BMBF im CASEPORT-Verbundprojekt (Kennziffer: 08NM111E) gefördert.

- **Therapiebestimmung:** Aufgrund der Symptomauswertung und sonstiger Daten des Patienten legt der Lernende fest, welche Art von Therapie zur Anwendung kommen soll (ggf. einschließlich Parametrierung, etwa bei der Dosierung von Medikamenten).
- **Therapiedurchführung:** Die Operation wird vom Lernenden durchgeführt, die Medikamente verabreicht etc. Eine nicht-medikamentöse Therapie ist eigentlich im CBT nicht nachbildbar.
- **Therapieüberwachung:** Der Lernende muss sich überzeugen, dass die von ihm verordnete Therapie auch tatsächlich den gewünschten Erfolg hat. Dafür ist es bei CBT nötig, die Auswirkungen der Therapie auf den Patienten zu simulieren um es zu ermöglichen, dass der Lerner etwa selbst erfassen kann, welche Risiken und Nebenwirkungen Therapien haben können.
- **Fallabschluss:** Der Lernende wird abschließend beurteilt. Der Fallabschluss passiert entweder zu einem vorgegebenen Zeitpunkt, wenn der Patient an einen anderen Arzt überwiesen wird, der Patient völlig genesen ist oder seine Krankheit soweit stabilisiert wurde, dass die weitere Überwachung nicht mehr interessant für den Lernenden ist.

Abb. 1: Therapieschleife



Es lässt sich erkennen, dass die größten Defizite der CBT bei der Symptomerhebung und der Therapiedurchführung liegen, denn diese beiden Gebiete lassen sich ohne aufwändige Enabling-Technologien durch bessere Modelle alleine nur schwer realisieren und wir wollen sie auch im Folgenden nicht behandeln. Eine Übersicht findet sich in [Rad02].

Ein weiterer Punkt zur Implementierung von realistischen Trainingssystemen ist die Möglichkeit der Therapieüberwachung und damit die Generierung von Folgesitzungen, denn realistische Folgesitzungen können einen wichtigen Beitrag zur Motivation des Lernenden liefern. Dieser kann zwar auch ohne Folgesitzungen bei falschen Therapien eine schlechte Beurteilung erhalten, wird diese Bewertung aber ohne die tatsächliche Konfrontation mit den Ergebnissen seiner Therapie als rein abstrakte Bestrafung hinnehmen und vergessen.

Für die Umsetzung dieses Konzeptes existiert ein weites Spektrum von Möglichkeiten:

- Angefangen bei statischen Folgesitzungen, die etwa in seitenbasierten Systemen wie CAMPUS ([Lev01]) zur Anwendung kommen,
- Über regelbasierte Modelle, wie sie in [Bich02] verwendet werden, um mit dem decision-support system CASE-PARTNER bzw. dem darin verwendeten Wissen Trainingsfälle zur Langzeit-Nachbehandlung von Stammzellen-Transplantationen generieren zu können,
- Bis hin zu (quantitativen) Simulationen ([Diet02], [Rad02]), die von den Aktionen des Lernalters prinzipiell unabhängig sind und enormes Wissen über Zusammenhänge des menschlichen Körpers benötigen, um korrekte oder auch nur realistische Therapie-Folgen berechnen zu können.

Wir werden im Folgenden zeigen, wie man, ausgehend von sehr schnell zu erstellenden, einfachen Folgesitzungen durch Hinzufügen von Wissen immer mehr Beschränkungen, denen diese einfachen Folgesitzungen unterliegen, aufheben kann.

## 2 Sitzungen im Trainingssystem

Eine Sitzung wird definiert als Vorgabe einer bestimmten Symptomatik und dem Erkennen der vorliegenden Erkrankungen und der Festlegung der anzuwendenden Therapien durch den Lerner. In einer Symptomatik ist jedem Attribut  $a$  aus der Menge  $A$  aller Attribute mit der Wertfunktion  $w: A \rightarrow V_a$  ein Wert  $v$  aus dem Wertebereich<sup>2</sup>  $V_a$  zugeordnet. Der Wertebereich jedes Attributs enthält den Normalwert  $v_o$  („nicht-pathologischer Wert“). Ein Symptom  $s_{ij}$  wird als abkürzende Bezeichnung des Zusammenhangs  $w(a_i) = v_j$  verwendet. Eine Symptomatik  $S$  ist eine Menge von Symptomen und kann auch Symptome der Form  $s_{i,0}$  beinhalten. Die Symptomatik  $S$  ist dem Lerner aber nicht sofort zugänglich: Jedem Attribut ist eine Untersuchung  $u_i$  aus der Menge aller Untersuchungen  $U$  zugeordnet. Erst wenn der Lerner das Ereignis  $u_i$  auslöst, also die Untersuchung anfordert, werden ihm alle zu diesem Attribut gehörenden Symptome  $s_{ij}$  bekannt gemacht. Weiterhin bezeichnet  $D$  eine Menge von Diagnosen  $d_i$  und  $T$  eine Menge von Therapien  $t_i$ . Dabei beinhaltet  $D$  auch die ausgezeichnete Null-Diagnose  $d_0$  („keine Erkrankung“) und  $T$  die Null-Therapie  $t_0$  („keine Therapie“).

Das Trainingssystem d3web.Train soll dem Lerner vermitteln: 1. Welche Untersuchungen muss er anfordern, um Diagnosen besser einschätzen zu können ( $D \rightarrow U$ ). 2) Wie schließt er richtig von einer Symptomatik  $S$  auf eine Menge von Diagnosen  $D$  ( $S \rightarrow D$ ). 3) Wie schließt er anschließend aufgrund von  $S$  und  $D$  auf eine Menge von Therapien  $D + S \rightarrow T$ . Das Trainingssystem kritisiert dabei das Vorgehen des Lerners, indem es dieses mit den Ergebnissen des Expertensystems d3web ([Pup96]) vergleicht. d3web versucht dabei, ausgehend von den Symptomen, die dem Lerner bekannt sind, selber die Lösungen zu finden und benutzt dazu u.a. Diagnose-Regeln der Form:

WENN *Bedingung* DANN „verändere Punktestand von  $d$  bzw.  $t$ “

Die Bedingung ist dabei ein logischer Ausdruck über Symptomen und Diagnosezuständen mit den Konnektoren *und*, *oder*, *nicht* und *nausm*. Abhängig von ihrem Punktestand sind Diagnosen und Therapien „etabliert“ bzw. „indiziert“, „verdächtig“ bzw. „sinnvoll“, „unklar“ oder „ausgeschlossen“. d3web leitet über diese Regeln zusätzlich her, welche Untersuchungen gerade notwendig sind, um weitere Entscheidungen treffen zu können.

Als Erweiterung von d3web.Train sollen Folgesitzungen dem Lerner die Wirkung von Therapien ( $T \rightarrow S$ ) vermitteln und ihn durch die Konfrontation mit realistischen Wirkungen von möglicherweise falschen Therapien motivieren, seinen virtuellen Patienten optimal zu behandeln.

Beim normalen Vorgehen zum Erstellen von Trainings-Fällen in einer neuen Domäne wird diese Domäne inkrementell anhand der Fälle erweitert, die Domäne enthält gerade genügend Regeln, damit d3web bei allen Fällen korrekt entscheidet. Deshalb soll es auch möglich sein, das nötige Wissen über Therapie-Folgen begleitend zur Erstellung der Fälle zu erweitern.

## 3 Statische Folgesitzungen

Die einfachste Art, Folgesitzungen zu ermöglichen besteht darin, diese fest vorzugeben. Dem Lerner wird beim Abschluss einer Sitzung mitgeteilt, ob sein Therapievorschlag richtig war und falls er es nicht war, welche Therapie stattdessen richtig gewesen wäre. In der nächsten Sitzung wird der Fall dann so präsentiert, wie er sich durch Anwendung der richtigen Thera-

---

<sup>2</sup> Attribute können multiple-choice, one-choice oder numerisch sein. Numerische Attribute besitzen einen begrenzten Wertebereich mit diskreten Werten oder ihr Wertebereich besteht aus Intervallen.

pie weiterentwickelt hätte. Neben der Tatsache, dass solche Folgesitzungen sehr schnell und einfach erzeugt werden können, haben diese noch weitere positive Eigenschaften: Die Ursprungs-Symptomatik kann durch mehrere Diagnosen bedingt worden sein, und die Folge-Symptomatik kann durch die Anwendung von mehreren Therapien verursacht worden sein, die unter Umständen auch miteinander wechselwirken können. Diese Eigenschaften in generierten Folgesitzungen zu erhalten wird nicht so einfach sein.

Statische Folgesitzungen haben aber mehrere Nachteile: Zum einen müssen alle Folgesitzungen so eingegeben werden als wären sie eigene Fälle. Der Aufwand dafür lässt sich aber begrenzen, wenn nur geänderte Werte eingegeben werden müssen. Zum anderen wird der Lerner nicht notwendigerweise mit den Folgen *seiner* Therapie, sondern mit den Folgen der richtigen Therapie konfrontiert. Weiterhin erhalten alle Lerner, die mit dem gleichen Fall starten, damit auch immer die gleiche Reihe von Folge-Fällen. Eine gewisse Abwechslung lässt sich erreichen, wenn für mehrere oder gar alle einigermaßen sinnvolle Therapien eigene Folge-Fälle erzeugt werden. Die Therapie des Lerners wird dann nur als falsch eingestuft, wenn kein zu ihr passender Folge-Fall existiert.

Ein viel gravierender Nachteil ist aber, dass das Wissen über Therapie-Wirkungen, das implizit in den Folge-Fällen vorliegt, nicht für andere Fälle genutzt werden kann und selbst für die Auswirkungen der gleichen Therapie bei einer anderen Symptomatik ein eigener Folge-Fall erzeugt werden muss.

Wir werden nun zeigen, wie sich das Wissen über Therapieeffekte, also die Wirkungen von Therapien, formalisieren lässt und sich derart eingegebenes Wissen zur Generierung vieler Folgesitzungen wieder verwenden lässt.

#### **4 Generierte Folgesitzungen durch Therapieeffekte**

Um den Therapieeffekt  $e_t$  einer Therapie  $t$  zu ermitteln, betrachten wir die Änderungen der Attribute zwischen der Ursprungs-Symptomatik  $S$  und der Symptomatik  $S'$  der Folgesitzung. Der Therapieeffekt besteht dann aus Änderungen  $c$  (*changes*), die die Symptomatik  $S$  in die Symptomatik  $S'$  überführen. Eine Änderung kann entweder ein Symptom hinzufügen ( $+s_{ij}$ ) oder entfernen ( $-s_{ij}$ ). Verändert ein Attribut  $a_i$ , das nur einen Wert annehmen kann, seinen Wert von  $v_j$  zu  $v_k$ , dann wird dies angegeben als  $\{-s_{ij}, +s_{ik}\}$ .

$$\text{Also ist } e_t = \{c\} = \{+s_{ij} \mid s_{ij} \notin S, s_{ij} \in S'\} \cup \{-s_{ij} \mid s_{ij} \in S, s_{ij} \notin S'\}.$$

Der Therapieeffekt besteht also genau aus den Änderungen, welche die Symptome, die in  $S'$  hinzugekommen sind, erzeugen, und diejenigen, die in  $S'$  verschwunden sind, löschen.

Zu einer beliebigen Symptomatik  $S$  und einer Therapie  $t$  mit einem derart spezifizierten Therapieeffekt  $e_t$  lässt sich eine Folgesymptomatik  $S'$  generieren mit:

$$S' = e_t(S) = \{s_{ij} \mid s_{ij} \in S, -s_{ij} \notin e_t\} \cup \{s_{ij} \mid +s_{ij} \in e_t\}$$

$S'$  enthält also alle Symptome, die in  $S$  vorhanden waren und von  $e_t$  nicht entfernt werden, und die Symptome, die von  $e_t$  verursacht werden. Folgesymptomatiken  $S'$  zu einer Menge  $T$  von Therapien werden nach folgendem Schema generiert:

$$S' = e_T(S) = e_{t_1} \circ e_{t_2} \circ \dots \circ e_{t_n}(S) = \{s_{ij} \mid s_{ij} \in S, \forall t \in T : -s_{ij} \notin e_t\} \cup \{s_{ij} \mid \exists t \in T : +s_{ij} \in e_t\}$$

Es werden also alle Therapieeffekte nacheinander (bzw. in beliebiger Reihenfolge) auf die Ursprungs-Symptomatik angewandt.  $S'$  enthält dann alle Symptome aus  $S$ , die von keinem Therapieeffekt entfernt werden und alle, die von einem der Therapieeffekte erzeugt werden.

Damit dies gilt, müssen mehrere Annahmen gemacht:

- Therapieeffekte sind absolute Effekte.
- Therapieeffekte wirken unabhängig von einer gegebenen Symptomatik.
- Therapien beeinflussen sich nicht gegenseitig und wirken nicht auf die gleichen Attribute.

Dadurch wird aber die Verwendbarkeit eines so spezifizierten Therapieeffekts stark eingeschränkt und die Generierung von realistischen Folgesitzungen ist somit nur begrenzt möglich. So kann damit etwa nicht modelliert werden, wie ein Medikament zur Milderung der Nebenwirkungen eines anderen Medikaments eingesetzt werden kann.

Deswegen werden wir unseren Formalismus nach und nach so erweitern, dass die gemachten Annahmen aufgehoben werden können.

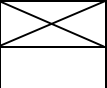
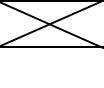
#### 4.1 Relative Therapieeffekte

Absolute Therapieeffekte sind nur dann verwendbar, wenn die Therapie ein Symptom tatsächlich unabhängig vom vorherigen Wert des betreffenden Attributs zur Folge hat bzw. die Therapie ein Symptom immer entfernt. Dies kann vor allem bei symptomatischen Wirkungen und Nebenwirkungen der Fall sein, so lassen etwa „starke Schmerzmittel“ „Schmerzen“ tatsächlich verschwinden und „Lithiumcarbonat“ verursacht sehr häufig „Händezittern“. Normalerweise ändert aber die Therapie den Wert eines Attributes in Abhängigkeit von seinem aktuellen Wert, z.B. *senken* „fiebersenkende Medikamente“ das Fieber nur, d.h. das Symptom „besonders hohe Temperatur“ wird ersetzt durch das Symptom „hohe Temperatur“, das Symptom „hohe Temperatur“ durch „leicht erhöhte Temperatur“ und nur das Symptom „leicht erhöhte Temperatur“ wird tatsächlich entfernt bzw. ersetzt durch „nicht-pathologischer Wert“.

Einen solchen Zusammenhang werden wir folgendermaßen angeben: Hat eine Therapie nur dann zur Folge, dass das Attribut  $a_i$  den Wert  $v_k$  annimmt, wenn es vorher den Wert  $v_j$  hatte, dann beinhaltet der Therapieeffekt nun das Element  $s_{ij} \mapsto s_{ik}$  (an Stelle der Elemente  $\{-s_{ij}, +s_{ik}\}$ ). Jetzt können für die einzelnen Werte des Attributs  $a_i$  entsprechende Änderungen  $s_{ij} \mapsto s_{ik}$  festgelegt werden.

Ein Therapieeffekt mit solchen Änderungen kann recht einfach in tabellarischer Form (siehe Abb. 2) angegeben werden.

**Abb. 2: Tabelle für die Eingabe eines Therapieeffekts**

$e_t$	$a_i \backslash v_j$	1	2	3	4
	1	–	$s_{1,1}$	$s_{1,2}$	...
	2	–	–		
	3				

Die ausgekreuzten Felder sind nicht belegbar, da der Wertebereich des Attributs einen entsprechenden Wert nicht enthält. Unbelegte Felder sollen anzeigen, dass die Therapie auf dieses Attribut keine Wirkung hat. Ein „–“ bei Attribut  $a_i$  und Wert  $v_j$  steht für die Aktion  $s_{ij} \mapsto s_{i,0}$  bzw.  $-s_{ij}$  und ein  $s_{ik}$  bei Attribut  $a_i$  und Wert  $v_j$  steht für  $s_{ij} \mapsto s_{ik}$ .

Wenn die Wertemenge eines Attributs geordnet ist – was bisher nicht verlangt wurde, die Nummern hatten keine Semantik – lässt sich der Therapieeffekt auf dieses Attribut in geeigneten Fällen auch einfacher angeben, nämlich als Formeln wie etwa  $c = s_{i,k} \mapsto s_{i,k-1}$ . Bei nu-

merischen Attributen (ohne Intervallen als Werten) könnte zudem auch eine Formel mit numerischen Werten als Änderung dem Therapieeffekt hinzugefügt werden:

$$c = w(a_i) \mapsto \max(v_o, w(a_i) - x).$$

## 4.2 Kontextabhängige Therapieeffekte

Die Folgen einer Therapie lässt sich aufteilen in die Folgen, die immer festgestellt werden können (eben symptomatische Wirkungen und Nebenwirkungen) und solche, die nur dann auftreten, wenn die Diagnose, gegen die die Therapie wirken soll, auch vorliegt. So wirken etwa die meisten Antibiotika nur gegen bestimmte Infektionen bzw. Bakterien und haben eventuell keine Wirkung, wenn es sich um ein anderes Bakterium handelt.

Wir erweitern unseren Formalismus derart, dass wir zu jedem Therapieeffekt einen Diagnose-Kontext angeben, unter dem der Therapieeffekt wirkt. Ein Diagnose-Kontext ist dabei eine Menge von Diagnosen, von denen eine vorliegen muss, damit die Wirkung eintritt. Die bisher angegebenen Therapieeffekte werden nun in die Effekte aufgeteilt, die immer eintreten – diese werden mit der Diagnose  $d_o$  („keine Erkrankung“) ausgezeichnet – und die, die nur bei bestimmten Diagnose-Kontexten  $K_D$  wirken. Typischerweise besteht  $D$  dabei aus sehr wenigen ähnlichen Diagnosen, da Therapien meist eine sehr spezifische Wirkung haben. Die Ursprungs-Symptomaten sind in d3web.Train zur Überprüfung des diagnostischen Wissens schon mit ihrem Diagnose-Kontext ausgezeichnet, so dass einer Therapie bei dieser Symptomatik leicht der richtige Therapieeffekt zugeordnet werden kann.

Wenn wir nun noch zulassen, dass Symptome ebenfalls zu einem Kontext beitragen können, dann können wir damit zwei weitere wichtige Eigenschaften nachbilden: Einmal, dass bestimmte Therapien von bestimmten Eigenschaften des Patienten abhängen, die nicht pathologisch sind, so z.B. die Wirkung eines Medikaments von Altersgruppe, Geschlecht, Unverträglichkeiten (die nicht pathologisch sein müssen). Zum anderen, dass bestimmte pathologische Symptome auch die Wirkung einer therapeutischen Maßnahme beeinflussen, aber keiner Diagnose zugeordnet werden können, weil diese Diagnose nicht im zugrunde liegenden Lehrmaterial enthalten ist. Im Expertensystem d3web wird bereits der Begriff einer *Kontextdiagnose* verwendet, um eine Diagnose zu bezeichnen, die dem Lerner nicht zur Auswahl steht, sondern nur vom Expertensystem als Hilfs-Abstraktion verwendet wird. Kontextdiagnosen bezeichnen dort solche Umstände wie „schwaches Herz“ oder „Leberschaden mit Auswirkungen“. Wenn nun ein bestimmtes Symptom zum Kontext eines Therapieeffekts beitragen soll, dann muss für dieses Symptom eine Kontextdiagnose erzeugt werden. Dies ist auch aus Sicht der Wissensakquisition günstiger, da der Experte beim Angeben des Kontexts nicht aus allen Symptomen wählen muss, sondern nur aus der Menge der Diagnosen.

Mit diesem Formalismus lassen sich nun auch die Wirkungen von Krankheiten modellieren – denn es können mit der Therapie  $t_0$  die Therapieeffekte der „Nicht-Therapie“ bei einer bestimmten Diagnose angegeben werden, also die Wirkung der Krankheit selbst. Allerdings gelten dabei noch folgende Einschränkungen:

- Krankheiten haben keinen Einfluss aufeinander und sind in ihrer Wirkung voneinander unabhängig.
- Es gibt nun zwar eine Veränderung der Symptomatik durch Krankheiten, aber keine Veränderung der Krankheiten selbst.

Diesen Formalismus so zu erweitern, dass die jetzt noch gültigen Einschränkungen (Therapien wechselwirken nicht untereinander, ebenso Diagnosen) aufgehoben werden können, ist möglich, allerdings ergibt sich dadurch eine exponentielle Steigerung der Anzahl an Kontext-Kombinationen.

Um die Wechselwirkung von Diagnosen berücksichtigen zu können, müsste die Bedeutung von  $K_D$  geändert werden.  $K_D$  soll bisher eine Menge von Diagnosen bezeichnen, von denen *eine* vorliegen muss, damit die Wirkung eintritt. Nun soll  $K_D = \{D_i\}$  eine Menge von Mengen von Diagnosen sein, mit der Bedeutung, dass der Therapieeffekt nur dann eintritt, wenn bei mindestens einer dieser  $D_i$  alle Diagnosen  $d_i \in D_i$  vorliegen.

Wollen wir nun noch die Wechselwirkungen von Therapien untereinander abbilden, müssten wir einen Therapie-Kontext  $K_T$  mit gleicher Semantik einführen:

$$e_{t,K_D,K_T} = \{c\},$$

wobei  $K_D$  den Diagnosekontext angibt und  $K_T$  den Therapiekontext.

Die Erhöhung der Komplexität des Kontexts eines Therapieeffekts geht hier einher mit einer immer weiteren Verkleinerung der Menge von Änderungen, die dieser Therapieeffekt schließlich verursacht. Eine weitere Aufspaltung der Therapieeffekte nach Dosierung, Kombination von Graden von Diagnosen und Kombinationen von Symptomen ist mit Hinblick auf die Wissensakquisition nicht mehr handhabbar.

Wir werden deshalb den Formalismus an dieser Stelle nicht mehr erweitern, sondern zu einem anderen Modell wechseln, welches uns ermöglicht, dass diese erhöhte Komplexität noch darstellbar und übersichtlich akquirierbar ist.

Zusätzlich werden wir zeigen, dass sich das bisher vorliegende Wissen teilweise in dem neuen Modell weiterverwenden lässt.

## **5 Diagnoseeffekte und Therapieeffekte auf Diagnosen**

Bei den Grund-Fällen war immer angegeben, welche Diagnosen  $D$  bei der Symptomatik vorliegen, und bei einem Therapieeffekt  $e_{t,K_D}$ , welche Symptome er wieder entfernt. Die Änderungen dieses Therapieeffekts machen aber eigentlich nur die Symptomveränderungen, die durch die Diagnose verursacht wurden, rückgängig - dieser Therapieeffekt ist also ein *kausaler Effekt*, da er die Ursachen der Symptome bekämpft. Die zu dieser Therapie gehörenden symptomatischen Wirkungen und Nebenwirkungen sind bereits als  $e_{t,K_{d_0}}$ , also dem von den vorliegenden Diagnosen unabhängigen Effekt, erfasst und können unverändert übernommen werden.

Die Wirkung einer Diagnose  $d$  konnte bereits als  $e_{t_0,K_d}$  angegeben werden, dieser *Diagnoseeffekt* wird nun mit  $e_d$  bezeichnet. Ein solcher Diagnoseeffekt kann nun auch wieder mit einem Diagnosekontext  $e_{d,K_D}$  versehen werden, dem auch wieder Kontextdiagnosen beigefügt werden können, die aber hier Abstraktion trivialer Attribute und Werte sein sollten. Damit kann etwa ausgedrückt werden, dass „Geschlecht“ = „weiblich“ bzw. die Kontextdiagnose „Patientin“ eine Voraussetzung für die Krankheit „Zervixkarzinom“ ist. Die Angabe von Diagnosen im Diagnosekontext benötigen wir noch, um Konflikte zwischen Diagnosen abschließen zu können.

Dieses Modell ist vergleichbar mit einfachen Überdeckungsmodellen mit Ausschlussbedingung (

[Bau02]), mit dem Unterschied, dass hier die Bedingungen nicht angeben, wann der Effekt zu verhindern ist, sondern es werden Bedingungen angegeben, die erfüllt sein müssen, damit der Effekt eintritt.

Mit solchen Diagnoseeffekten bietet sich nun neben der Generierung von Folgesetzungen auch die Möglichkeit, die Ursprungssymptomatik auch zu generieren. Durch Anwenden der Diagnoseeffekte auf eine fast leere Grundsymptomatik („Alter“, „Größe“, „Gewicht“, „Zigarettenkonsum“ = „mehr als 20 pro Tag“, etc.) lassen sich nun auch völlig neue Fälle erzeugen. Allerdings ist dazu ein beträchtlicher Mehraufwand nötig, um zusätzliches Wissen in Form von Constraints bereitzustellen, mit denen die Generierung von nicht sinnvollen Werten verhindert werden kann ([Bel99]).

Wenn zu jeder möglichen vorliegenden Diagnose dieses Wissensgebietes ein solcher Diagnoseeffekt vorliegt, dann können wir die Therapieeffekte so erweitern, dass sie nicht mehr nur auf die Symptome (symptomatische und Neben-Wirkungen) wirken. Zusätzlich werden nun die kausale Wirkungen, also die Änderungen der Diagnosen, angegeben, wobei eine Therapie nur Diagnosen entfernen kann ( $-d$ ). Damit lassen sich nun *alle* Therapieeffekte einer Therapie zusammenfassen zu:

$$e_t = \{-d_i, -d_j, \dots, +s, -s, s_{ij} \mapsto s_{ik}, \dots\}.$$

Diagnosekontexte werden zwar noch benötigt, aber sie können nun nur noch Kontextdiagnosen beinhalten.

Eine Eigenschaft des vorhergehenden Modells geht dabei verloren: Die relativen Effekte einer Therapie konnten bisher dazu verwendet werden, ein ‚allmähliches Verbessern‘ eines Attributes zu erzeugen mit  $e_t = \{s_{il} \mapsto s_{ik}, s_{ik} \mapsto s_{ij}, s_{ij} \mapsto s_{i,0}\}$ , wenn etwa  $s_{ij}$ ,  $s_{ik}$  und  $s_{il}$  für die Werte „leicht erhöht“, „stark erhöht“, „lebensbedrohlich erhöht“ stehen. Damit dies mit Diagnoseeffekten wieder möglich wird, werden wir die absoluten Effekte der Therapien bezüglich der Diagnosen in relative Effekte erweitern.

## 5.1 Relative Effekte auf Diagnosen

Aus Gründen der Ökonomie der Eingabe werden Diagnosen mit einem Diagnose-Grade  $d_i^g$  annotiert, mit dem sich die Schweregrad und das Stadium einer Krankheit ausdrücken lassen. Bisher konnten verschiedene Erscheinungsformen einer Krankheit nur dadurch berücksichtigt werden, dass sie auf verschiedene Diagnosen abgebildet wurden – nun können sie zusammenfassend in Grade derselben Diagnose  $d_i$  abgebildet werden. Der Grad 0 einer Diagnose soll das Nicht-Vorhandensein dieser Diagnose bezeichnen, d.h.  $d_i^0 \equiv d_0 \equiv d_0^0$ .

Mit solchen *dynamischen Überdeckungsmodellen* ([Bau03]) lassen sich nun Therapieeffekte, die eine Krankheit allmählich entfernen, angeben als

$$e_t = \{d_i^h \mapsto d_i^g, d_i^g \mapsto d_i^0, \dots\}.$$

Bei den Diagnoseeffekten ist dann intuitiv natürlicher angegeben, dass etwa eine „Infektion“ vom Grad „leicht“ nur „Temperatur“ = „leicht erhöht“ verursacht und eine vom Grad „schwer“ eben „Temperatur“ = „stark erhöht“. Die Anwendung der Therapie „Antibiotika“ ändert dann den Grad der Diagnose zuerst von „schwer“ zu „leicht“, bevor die Krankheit dann nach einer weiteren Anwendung vollständig kuriert wird.

Wenn wir nun noch zulassen, dass Diagnoseeffekte auch auf Diagnosen wirken, dann lassen sich sehr leicht Krankheitsverläufe modellieren, nämlich dass sich eine Krankheit ohne zutun selbst verändert durch

$$e_d = \{d^h \mapsto d^s, d^s \mapsto d^0, \dots\},$$

oder dass eine Krankheit eine andere Krankheit verursacht mit

$$e_{d_i} = \{+d_j^s, \dots\}.$$

Wenn die Effekte verschiedener Diagnosen und Therapien berechnet werden sollen, benötigen wir noch eine Konfliktlösungsstrategie, wenn einer der folgenden Punkte eintritt: Mehrere Diagnosen wirken auf das gleiche Symptom oder mehrere Therapien wirken auf die gleiche Diagnose oder das gleiche Symptom.

## 5.2 Konfliktlösung bei der Verrechnung von Effektwirkungen

Einen Großteil der Konflikte – alle Konflikte von Diagnosen mit Therapien - werden behandelt, wenn die Folgesitzungen mehrstufig generiert werden:

- Zuerst werden alle kausalen Wirkungen der gewählten Therapien auf die aktiven Diagnosen angewandt
- Anschließend werden die Änderungen aufgrund der Diagnoseeffekte aller nun aktiven Diagnosen durchgeführt
- Abschließend wirken sich die symptomatischen und Neben-Wirkungen der gewählten Therapien aus

Die noch nicht behandelten Konflikte, wenn mehrere Diagnosen oder mehrere symptomatischen und Neben-Wirkungen von Therapien auf das gleiche Attribut wirken, können wir durch Einführung von *Abnormitäten* lösen: Für jedes betroffene Attribut muss eine teilweise Ordnung der Wertemenge aufgrund der Abnormität angegeben werden. Diese gibt an, wie weit der entsprechende Wert vom Wert  $v_0$  („nicht-pathologischer Wert“) bezüglich seiner Krankhaftigkeit abweicht. Dabei kann es mehrere Abnormitätsmaßstäbe geben, der Wert von „Körpertemperatur“ kann z.B. „lebensbedrohlich hoch“, „sehr hoch“ oder „leicht erhöht“ sein, aber auch „leicht zu niedrig“, „sehr niedrig“ oder „lebensbedrohlich niedrig“. Hier lassen sich die ersten drei und die zweiten drei Werte jeweils untereinander ordnen, nicht aber Werte aus den verschiedenen Gruppen wie etwa „sehr hoch“ und „sehr niedrig“.

Der Wert eines Attributs mit mehreren einwirkenden Diagnosen oder Therapien wird mittels der Abnormitäten nach folgenden Heuristiken bestimmt:

- Wirken mehrere Diagnosen, dann erhält das Attribut  $a$  den Wert mit der *höchsten* Abnormität unter allen Werten, die  $a$  durch die Effekte dieser Diagnosen annehmen kann.
- Wirken mehrere Therapien, dann erhält  $a$  den Wert mit der *niedrigsten* Abnormität unter allen Werten, die  $a$  durch die Effekte dieser Therapien annehmen kann.

Diese Heuristiken werden motiviert durch die Annahme, dass sich die Diagnosen bzw. Therapien mit der stärksten Wirkung bei der Bestimmung der Symptomatik durchsetzen.

Für alle jetzt noch nicht behandelten Fälle, dass mehrere Diagnosen (oder Therapien) bei einem Attribut verschiedene Werte nicht vergleichbarer Abnormität setzen wollen, muss der Experte eine eigene sinnvolle Präferenz angeben.

Es ist zu erwarten, dass sich mit diesem Modell bereits realistische und für unsere Zwecke ausreichende Sitzungen zur Therapieüberwachung generieren lassen. Eine Sitzung wird bestimmt durch die aktiven Diagnosen in verschiedenen Graden, in der der Lerner aus einer Menge von Therapien beliebige auswählen darf. Daraufhin wird eine Folgesitzung generiert, die sowohl das Fortschreiten der Krankheiten, als auch die kausalen Wirkungen und symptomatischen und Neben-Wirkungen der gewählten Therapien berücksichtigt.

Die Folgesitzungen sollen dem Lerner die Möglichkeit bieten, anhand der Auswirkungen seiner Therapien zu entscheiden, ob und wie er die Therapien verändern soll um den möglicherweise noch kranken Patienten weiter zu behandeln.

## **6 Diskussion**

Wir haben verschiedene Ansätze zur Generierung von Folgesitzungen gezeigt: statische Folgesitzungen, Sitzungen die durch Anwendung von Therapieeffekten erzeugt werden und solche, bei denen noch zusätzlich Diagnoseeffekte verwendet werden.

- Feste Folgesitzungen haben den Vorteil, dass ohne jedes formalisierte Wissen zu einer Startsituation schnell eine Folgesituation erstellt werden kann.
- Einfache Therapieeffekte und besonders relative, Kontext-abhängige Therapieeffekte sollten schon ausreichen, eine Vielzahl von einfachen Fällen zu erzeugen.
- Überdeckungsmodelle, die reale Vorgänge am besten nachbilden, bieten eine elegante Möglichkeit, Verläufe von Krankheiten und den Einfluss von Behandlungen nachzubilden, haben aber (für unsere bisherigen Anwendungen) den Nachteil, dass das bisher von d3web benötigte diagnostische Wissen kaum wiederverwendet werden kann.

In [Bau03] werden weitere Ergänzungen von Überdeckungsmodellen gezeigt, die zusätzliche Eigenschaften von Diagnosen erfassen können, so z.B. stochastische Effekte, mit denen zu einer spezifischen Symptomatik mehr als nur eine Folgesitzungen erzeugt werden kann. Es gibt allerdings einen guten Grund, Stochastizität nicht zu verwenden: Fälle (und damit auch Folgesitzungen) müssen stets verifizierbar bleiben, damit sie bei der Lehre und insbesondere in Prüfungen verwendet werden können. Dies ist bei den Fällen schon schwierig, die mit Modellen generiert werden, die mit unserem Formalismus beschrieben wurden - bei generierten Fällen mit Zufallselement jedoch unmöglich. Wir können den Mangel an Stochastizität teilweise kompensieren, indem wir verschiedene leicht unterschiedliche Effekte angeben und bei einer spezifischen Ursprungssitzung angeben, welche jeweils verwendet werden sollen. Damit würden verschiedene Fortsetzungen trotz gleicher Maßnahmen in der gleichen Situation möglich, allerdings ist dafür das Wissen mehrfach einzugeben.

Es ist weiterhin denkbar, dem Lerner die Möglichkeit zu geben, Therapien in unterschiedlicher Dosierung auszuwählen. Bei den Therapien, wie wir sie verwendet haben, wird davon ausgegangen, dass der Lerner nur folgert, welche Therapie er anwenden muss, die tatsächliche Dosierung aber etwas ist, was sich aufgrund einiger Daten des Patienten („Gewicht“, „Alter“, etc.) sehr einfach errechnen lässt. Als weitere Herausforderung für den Lerner kann aber auch noch die zusätzliche Auswahl der richtigen Dosierung interessant sein. Dies verkompliziert aber wiederum stark die Wissensakquisition, da nun für die meisten Therapien leicht verschiedene Therapieeffekte für die verschiedenen Grade anzugeben sind.

Es wird aber immer nötig bleiben, die Auswahl des Lerners auf eine bestimmte Menge von in dieser Situation sinnvollen Therapien zu beschränken. Es ist nicht sinnvoll, das Wissen einzugeben, das nötig ist, um für alle Therapien und Diagnosen (und –Grade) korrekte Folgesitzungen generieren zu können. Der Anspruch an ein Trainingssystem kann nicht sein, alle möglichen Krankheitsbilder des Wissensgebietes korrekt zu generieren, sondern nur die, die vom Lehrer als sinnvoll erachtet werden. Wenn die Generierung der Folgesitzung aufgrund einer abwegigen Therapie mit einem entsprechenden Kommentar unterbunden wird, dann schmälert das nicht die Leistungsfähigkeit des Trainingssystems.

## 7 Ausblick

Der nächste Schritt wird sein, die vorgeschlagenen Modelle einzusetzen und zu evaluieren, wie Lehrer die erhöhte Wissensengabe meistern und die Lerner auf die unterschiedlich realistischen Folgesitzungen reagieren. Dabei kann es durchaus auch passieren, dass eine oder beide Gruppen gar nicht alle Möglichkeiten der Modelle nutzen wollen, sondern bereits mit einfacheren Modellen zufrieden sind.

Zudem eröffnen die Verwendung der Historie und das Abstrahieren dieser Werte für das Expertensystem neue Möglichkeiten des Schließens zum Bestätigen von Diagnosen und Therapien. So kann etwa durch Regeln der Form

WENN  $t_i$  AUSGEWÄHLT UND  $Trend(a_i) = normalisierend$  DANN WAR  $t_i$  KORREKT  
und

WENN  $t_i$  AUSGEWÄHLT UND  $Trend(a_i) = verschlechternd$  DANN WAR  $t_i$  FALSCH

das Expertensystem in der Lage sein, Therapien zu bewerten und das Trainingssystem kann damit die Therapieauswahl des Lerners kritisieren.

## Literatur

[Bau02] *Baumeister, J.; Seipel, D.*: Diagnostic Reasoning with Multilevel Set-Covering Models

in: Proceedings 13th. International Workshop on Principles of Diagnosis (DX-02), Semmering, Austria, 2002

[Bau03] *Baumeister, J.; Seipel, D.; Puppe, F.*: Incremental Development of Diagnostic Set-Covering Models with Therapy Effects

to appear in: Electronic Transactions on Artificial Intelligence

[Bel99] *Belli, V.*: Constraint-basierte Fallgenerierung in Diagnosesystemen

Diplomarbeit, Lehrstuhl für Künstliche Intelligenz und Angewandte Informatik, Universität Würzburg, 1999

[Bich02] *Bichindaritz, I.; Sullivan M.D., K.M.*: Generating Practice Cases for Medical Training from a Knowledge-Based Decision-Support System

in: Proceedings Workshop on Case-Based Reasoning for Education and Training, September 4<sup>th</sup>, 2002, Robert Gordon University, Aberdeen, Scotland

[Diet02] *Dietrich, J.W.*: Der Hypophysen-Schilddrüsen-Regelkreis. Entwicklung und klinische Anwendung eines nichtlinearen Modells.

Berlin, Logos-Verlag, 2002

[Hoer02] *Hörnlein, A.; Betz., C.; Puppe, F.*: Redesign eines generativen, fallbasierten Trainingssystems für das WWW in d3web.Train

in: *Bernauer J.; Fischer, M.R.; Leven, F.J.; Puppe, F.; Weber, M. (Hrsg.)*: Rechnergestützte Lehr- und Lernsysteme in der Medizin: Proceedings zum 6. Workshop der GMDS AG Computergestützte Lehr- und Lernsysteme in der Medizin, Fachhochschule Ulm, 11.-12. April 2002, Shaker-Verlag, Aachen 2002

[Lev01] *Leven, F.J.; Heid, J.; Riedel, J.; Singer, R.; Geiss, H.K.; Jünger, J.; Tönshoff, B.:* CAMPUS: Eine Shell zur Implementierung fallbasierter Lehr- und Lernformen in reformierten Medizinstudiengängen integriert in ein überregionales Portal für Web-basiertes Training in der Medizin

in: Forschungsbericht Fachhochschule Heilbronn, Heilbronn, 2001

[Pup96] Puppe, F.; Gappa, U.; Poeck, K.; Bamberger, S.: Wissensbasierte Diagnose- und Informationssysteme

Springer, 1996

[Rad02] Radetzky, A.; Nürnberger, A.: Visualization and simulation techniques for surgical simulators using actual patient's data

in: Artificial Intelligence in Medicine, Volume 26, Issue 3, 2002