

# Zum maschinellen Lernen für benutzeradaptive Systeme am Beispiel Bayes'scher Netze

**Frank Wittig**

Fachrichtung 6.2 - Informatik, Universität des Saarlandes,  
Postfach 15 11 50, 66041 Saarbrücken  
wittig@cs.uni-sb.de

## Zusammenfassung

Der vorliegende Beitrag beleuchtet die engen Zusammenhänge zwischen der Aufgabenstellung beim maschinellen Lernen und der Aufgabenstellung benutzeradaptiver Systeme. Es werden kritische Problemstellungen identifiziert und diskutiert, die typischerweise die direkte Anwendung maschineller Standardlertechniken im Kontext benutzeradaptiver Systeme erschweren. Im zweiten Teil des Beitrags wird eine Konzeption vorgestellt, die einige dieser Probleme eines Einsatzes maschineller Lernverfahren Bayes'scher Netze in benutzeradaptiven Systemen durch Integration existierender und speziell für die Benutzermodellierung modifizierter bzw. neu entwickelter Verfahren löst.

## 1 Einleitung

Techniken des maschinellen Lernens werden verstärkt in benutzeradaptiven Systemen eingesetzt (Webb, Pazzani & Billsus, 2001)—sei es im Zuge der explosionsartigen Entwicklung des World Wide Web mit einer Vielzahl interaktiver Seiten oder im Rahmen der wachsenden Bedeutung mobiler Systeme. Diese beiden Beispieldomänen legen nahe, dass beim Einsatz maschineller Lernverfahren in benutzeradaptiven Systemen besondere Anforderungen an die Methoden gestellt werden.

Ziel des ersten Teil dieses Beitrags ist es, den engen Zusammenhang zwischen Techniken des maschinellen Lernens und benutzeradaptiven Systemen mit den entsprechenden kritischen Problemstellungen am Beispiel Bayes'scher Netze herauszuarbeiten. Bayes'sche Netze (Pearl, 1988) sowie die zugehörigen Lernverfahren gewinnen wegen ihrer Fähigkeit zur Repräsentation von und dem Schlussfolgern unter Unsicherheit zunehmend an Bedeutung in benutzeradaptiven Systemen.

Im zweiten Teil wird eine Gesamtkonzeption des maschinellen Lernens Bayes'scher Netze vorgestellt, die existierende sowie modifizierte bzw. neu entwickelte Verfahren integriert, um die im ersten Teil identifizierten Schwächen der Lernverfahren im Benutzermodellierungskontext zu behandeln.

## 2 Maschinelles Lernen und benutzeradaptive Systeme

Mitchell (1997) definiert das maschinelle Lernproblem in allgemeiner Form wie folgt:

**Definition 1 (Maschinelles Lernen)** *Ein Computer-Programm lernt wenn sich seine Performanz hinsichtlich der von ihm zu bearbeitenden Aufgabe  $A$  bezüglich eines Performanzmaßes  $Q$  mit der gesammelten Erfahrung  $E$  verbessert.*

Mit dieser Formulierung des maschinellen Lernproblems wird implizit zwischen zwei Komponenten eines Systems, das maschinelles Lernen realisiert, unterschieden: (a) der *Lernkomponente*, welche die Erfahrungen bzw. Daten  $E$  auswertet, um das Ergebnis der im Rahmen der (b) *Performanzkomponente* behandelten Aufgabe  $A$  zu verbessern.<sup>1</sup> Betrachtet man als Beispiel ein lernendes Schachprogramm, so

---

<sup>1</sup>Im allgemeinen Modell eines maschinellen Lernsystems werden zwei weitere Module unterschieden, die in dieser Arbeit nicht von Interesse sind (siehe z.B. Mitchell, 1997).

sind dies einerseits (a) das Modul, das gespielte Partien hinsichtlich vielversprechender Strategien analysiert, und andererseits (b) das Modul, das während des Spiels den jeweiligen potentiell besten nächsten Zug bestimmt.

Zur Formulierung einer wohldefinierten maschinellen Lernaufgabe müssen gemäß Definition 1 (i) die zu behandelnde Aufgabe  $A$ , (ii) die (Art der) verfügbaren bzw. zu sammelnden Erfahrungen  $E$  (im Weiteren auch als *Trainings-* bzw. *Adaptionsdaten* bezeichnet), und (iii) das zu verwendende Performanzmaß  $Q$  spezifiziert werden.

Definition 1 des maschinellen Lernproblems legt eine direkte Übertragung auf den Kontext benutzeradaptiver Systeme in folgender Weise nahe (vgl. Langley, 1997):

**Definition 2 (Benutzeradaptives System)** *Ein benutzeradaptives System ist ein interaktives Softwaresystem, das seine Interaktionsfähigkeit mit seinen Benutzern auf der Basis von Erfahrungen mit den Benutzern verbessert.*

Das bedeutet in Bezugnahme auf die Formulierung des allgemeinen maschinellen Lernproblems nach Definition 1: Die Aufgabe  $A$  entspricht der Interaktion mit den Benutzern, das Performanzmaß  $Q$  ist ein Maß der Qualität der Interaktion und die Erfahrungen bzw. Trainingsdaten  $E$  sind die Interaktionsdaten, die entweder zum aktuellen Benutzer und/oder zu früheren Benutzern des Systems erhoben wurden.

Jameson (2002) unterscheidet—in Analogie zur Unterscheidung zwischen Lern- und Performanzkomponente beim allgemeinen maschinellen Lernen—in diesem Kontext zwischen den beiden Komponenten zur (i) *Aquisition* des Benutzermodells (engl. *user model acquisition*) und (ii) der *Anwendung* des Benutzermodells (engl. *user model application*). Damit repräsentiert das Benutzermodell die Schnittstelle zwischen Lern- und Performanzkomponente in benutzeradaptiven Systemen.

### 3 Problemstellungen beim maschinellen Lernen im Kontext benutzeradaptiver Systeme am Beispiel Bayes'scher Netze

Es lassen sich entscheidende Kriterien der Anwendung maschineller Lernverfahren im Kontext benutzeradaptiver Systeme identifizieren, die die direkte Übertragung bzw. Anwendung entsprechender Algorithmen in einem solchen System erschweren oder sogar unmöglich machen können. Sie werden in diesem Abschnitt am Beispiel des Einsatzes maschineller Lernverfahren für Bayes'sche Netze in benutzeradaptiven Systemen diskutiert (vgl. Webb et al., 2001, für eine ähnliche Diskussion einer Teilmenge der angeführten Kriterien). Diese Problemstellungen sind zum Teil stark miteinander verknüpft und können teilweise mit den gleichen Lösungsansätzen behandelt werden.

Die folgende Diskussion wird hinsichtlich der Lernverfahren Bayes'scher Netze<sup>2</sup> auf einer abstrakten Ebene geführt werden. Es genügt zu wissen, dass es sich bei Bayes'schen Netzen um einen Formalismus zur Repräsentation und zum Schlussfolgern unter Unsicherheit handelt und dass sie aus zwei Komponenten bestehen: (a) einem gerichteten azyklischen Graphen—die *Struktur* des Netzes—welcher die kausalen Zusammenhänge zwischen den Variablen der modellierten Domäne kodiert, und (b) mit den Kanten der Struktur assoziierter Tabellen bedingter Wahrscheinlichkeiten (engl. conditional probability tables, CPTs), die die quantitativen probabilistischen Zusammenhänge zwischen den Variablen des Bayes'schen Netzes repräsentieren.

#### 3.1 Wenige verfügbare Trainingsdaten

Die direkte Anwendbarkeit von Standardalgorithmen aus dem Bereich des maschinellen Lernens im Kontext benutzeradaptiver Systeme wird in vielen Szenarien dadurch verhindert, dass nur relativ wenige Trainingsdaten zur Aquisition des Benutzermodells zur Verfügung stehen. Oft findet nur eine begrenzte Anzahl an Interaktionen zwischen Benutzer und System statt. Als Beispiel kann hierzu die Situation dienen, in der ein Kunde eines benutzeradaptiven WWW-CD-Shops nur gelegentlich eine CD bestellt. Dennoch sollen möglichst von Beginn jedes Interaktionsprozesses an, sinnvolle Adaptionentscheidungen getroffen werden können, um ein adaptives Verhalten eines solchen Systems zu realisieren. Der

---

<sup>2</sup>Eine Übersicht über maschinelle Lernverfahren Bayes'scher Netze gibt z.B. Heckerman (1995).

Benutzer möchte nicht gezwungen sein, erst eine Vielzahl an persönlichen Angaben oder aufwendige Testbewertungen zu ausgewählten Beispielartikeln machen zu müssen, bevor ihm die adaptive Funktionalität des Systems zur Verfügung steht. Damit ist die Verfügbarkeit von Algorithmen, die in der Lage sind, eine möglichst schnelle adäquate Adaption zu ermöglichen, von entscheidender Bedeutung für den Erfolg von benutzeradaptiven Systemen in vielen der potentiellen Einsatzszenarien.

Beim Einsatz von Batchlernverfahren zur Akquisition der Benutzermodelle muss in Situationen, die sich durch geringe Mengen an Trainingsdaten auszeichnen, die *Overfitting*-Problematik berücksichtigt werden: Eine zu starke Spezialisierung erlernter allgemeiner Benutzermodelle auf die Trainingsdaten kann insbesondere dann auftreten, wenn die erhobenen Daten auf einer zahlenmäßig kleinen Anzahl an Benutzern basieren oder die Ausprägungen der Nutzereigenschaften sehr heterogenen individuellen Charakter aufweisen. Es ist dann nur in sehr eingeschränkter Form möglich, ein allgemein einsetzbares Modell zu erlernen.

Diese Problematik kann mit Bayes'schen Netzen in vielen Fällen folgendermaßen angegangen werden: Ein entweder manuell auf der Basis theoretischer Überlegungen spezifiziertes oder anhand der Daten anderer Benutzer maschinell erlerntes Bayes'sches-Netz-Benutzermodell wird als Ausgangspunkt eines Adaptionvorgangs an den individuellen Nutzer verwendet. Es stehen Adaptionsverfahren für die bedingten Wahrscheinlichkeiten Bayes'scher Netze zur Verfügung (Olesen, Lauritzen & Jensen, 1992), die anhand einer einzelnen Beobachtung eine Modellanpassung vornehmen können. Schwierig zu behandeln sind Situationen, in denen weder Hintergrundwissen noch Daten anderer Benutzer vorliegen. Hier kann es relativ lange dauern, bis im Rahmen der Adaptionsverfahren ein Modell erlernt wird, welches brauchbare Ergebnisse liefert.

### 3.2 Inter-individuelle Unterschiede zwischen Benutzern

Charakteristisch für benutzeradaptive Systeme sind die auftretenden individuellen Unterschiede zwischen einzelnen Benutzern. Ohne sie gäbe es keine Existenzberechtigung für einen Großteil der benutzeradaptiven Systeme: Jeder potentielle Benutzer könnte in gleicher Art und Weise behandelt werden. Deshalb müssen—soweit vorhanden—existierende maschinelle Lernverfahren verwendet oder neue Methoden entwickelt werden, die in der Lage sind, genau diese Unterschiede zu erkennen und im Rahmen der Adaption auszunutzen.

Lernverfahren für Bayes'sche Netze eignen sich im Allgemeinen gut zur Berücksichtigung individueller Unterschiede. Eine einfache Möglichkeit ist die Aufnahme von expliziten individuellen Parametervariablen in die Struktur des Netzes. Solche Parametervariablen modellieren individuelle Eigenschaften der Benutzer wie z.B. das Vorwissen eines Lernenden in einem intelligenten Lehr-/Lernsystem. Einmal ermittelt, können die benutzerspezifischen Werte dieser Parametervariablen vom System abgelegt und für zukünftige Interaktionen mit diesem Benutzer verwaltet werden. Weiterhin kann wie beschrieben ein allgemeines Ausgangsnetz erlernt werden, welches mit Hilfe der angesprochenen Adaptionsalgorithmen an den individuellen Benutzer angepasst wird. Hier erhält man allerdings keine derart kompakte explizite Repräsentation der individuellen Unterschiede wie es mit Parametervariablen der Fall ist. Außerdem berücksichtigen die existierenden Adaptionsverfahren bislang keinerlei Informationen zu einzelnen spezifischen Aspekten der Benutzermodelle. So existieren typischerweise Eigenschaften, bezüglich derer alle Benutzer weitestgehend übereinstimmen, so dass lediglich geringe Anpassungen vorgenommen werden müssen. Hinsichtlich anderer Teile der Benutzermodelle kann es allerdings notwendig sein, radikalere Veränderungen der Modelle im Rahmen des Anpassungsprozesses durchzuführen.

### 3.3 Dynamische Domänen

Eine weitere charakteristische Eigenschaft der Domänen benutzeradaptiver Systeme ist die Tatsache, dass die Eigenschaften, Interessen, Ziele etc. der Benutzer oftmals zeitabhängigen Veränderungen unterliegen. Das entsprechende Problem ist im maschinellen Lernen unter dem englischen Begriff '*concept drift*' (Widmer & Kubat, 1996) bekannt. Ein Beispiel hierfür ist ein adaptiver WWW-Agent zur Zusammenstellung von Nachrichten wie das NEWSDUDE-System (Billsus & Pazzani, 1999): Es können zeitabhängige, benutzerspezifische Interessensverschiebungen auftreten, z.B. kann vor einer anstehenden Wahl sich ein Interessenschwerpunkt auf Nachrichten der Kategorie 'Politik' bilden, der nach dem Wahltermin wieder

rapide an Gewicht verliert, wohingegen gleichzeitig eine zeitnah stattfindende Fußballweltmeisterschaft in den Fokus des Interesses rückt. Es muss beachtet werden, dass solche zeitabhängigen Veränderungen potentiell in verschiedenen Zeitfenstern beobachtet werden können.

Bei solchen dynamischen Aspekten einer Domäne handelt es sich oft nicht um tatsächliche Veränderungen der Benutzercharakteristika, sondern lediglich um Eigenschaften, die zu einem bestimmten Zeitpunkt noch nicht vom benutzeradaptiven System beobachtet wurden und folglich noch nicht im Benutzermodell repräsentiert sind. Beispielsweise könnte ein Kunde eines Online-CD-Shops bislang nur Jazz-CDs gekauft haben, obwohl er prinzipiell auch an klassischer Musik interessiert ist.

Schäfer (1998) hat gezeigt, dass Benutzermodelle in Form *dynamischer* Bayes'scher Netze<sup>3</sup> ein adäquates Mittel zur Repräsentation temporaler Aspekte in benutzeradaptiven Systemen sind. Die existierenden CPT-Adaptionstechniken Bayes'scher Netze bieten die Möglichkeit, ältere Trainingsdaten, „zu vergessen“. Ein handhabbares Verfahren, die Struktur Bayes'scher Netze in dynamischen Domänen unter Berücksichtigung der besonderen Anforderungen benutzeradaptiver Systeme anzupassen, existiert bislang nach Wissen des Autors nicht.

### 3.4 Komplexität der Lernverfahren / Effizienz zur Laufzeit

Gerade in WWW-basierten oder mobilen Systemen, bei denen die Notwendigkeit schneller Antwortzeiten auf der Hand liegt, ist die Effizienz der verwendeten Verfahren ein entscheidendes Kriterium der Einsetzbarkeit eines benutzeradaptiven Systems. Webshops wie der des Online-Buchhändlers AMAZON<sup>4</sup> müssen in der Lage sein täglich Millionen von Anfragen zu beantworten. Mobile Systeme sind oft durch beschränkte technische Ressourcen wie leistungsärmere CPUs und geringere Speicherkapazitäten gekennzeichnet. Somit sind (Lern- bzw. Adaptionen-)Verfahren von Vorteil, die unter solchen einschränkenden Randbedingungen eines Systems möglichst effizient arbeiten können.

Diese Problematik führt dazu, dass in kommerziellen Anwendungen oft nur ein Teil der potentiell möglichen und wünschenswerten Adaptionfähigkeiten realisiert wird. Vielfach wird in solchen Situationen bislang komplett auf eine automatische Anpassung durch das System verzichtet. Statt dessen wird dem Benutzer die Möglichkeit geboten, bestimmte Aspekte des Systemverhaltens manuell zu konfigurieren. Man spricht dann von *adaptierbaren* (im Gegensatz zu *adaptiven*) Systemen. Beispiele solcher Systeme finden sich in vielen Portalseiten wie z.B. bei YAHOO!<sup>5</sup>, wo sich der Benutzer eine seinen Wünschen entsprechende Startseite zusammenstellen kann. Er hat die Möglichkeit, aus einem Angebot an verschiedenen Diensten wie Börsennachrichten, Sportnachrichten, Wetter usw. auszuwählen. Eine weitergehende automatische Anpassung findet dann nicht mehr statt.

Hinsichtlich der Komplexität maschineller Lernverfahren für Bayes'sche Netze müssen vier Fälle unterschieden werden: (a) das Lernen der bedingten Wahrscheinlichkeiten mit vollständigen Daten, (b) das Lernen der bedingten Wahrscheinlichkeiten mit unvollständigen Daten, (c) das Lernen der Struktur (inklusive der CPTs) mit vollständigen Daten und (d) das Lernen der Struktur mit unvollständigen Daten. Für Fall (a) existieren effiziente, einfache (Batch)-Lernverfahren. Die restlichen Lernaufgaben (b) - (d) erfordern aufwendigere Methoden, die im Allgemeinen nicht für einen Einsatz zur Laufzeit eines Systems geeignet sind. Sie müssen (semi-)offline angewendet, d.h., entweder vor der Interaktionsphase oder zwischen zwei Benutzersitzungen. Die existierenden Adaptionsverfahren zur Anpassung der bedingten Wahrscheinlichkeiten stellen in dieser Hinsicht aufgrund ihrer Effizienz kein Hindernis dar. In diesem Zusammenhang sind wiederum Methoden zur Anpassung der Strukturen (beispielsweise durch wiederholtes Neulernen) problematisch, die nicht für einen Einsatz in Laufzeitszenarien geeignet sind.

### 3.5 Interpretierbarkeit der erlernten Modelle

In benutzeradaptiven Systemen spielt die *Interpretierbarkeit* bzw. die *Erklärbarkeit* der Benutzermodelle eine wichtige Rolle. Diese Eigenschaft ist eng verbunden mit den beiden Begriffen der *Vorhersagbarkeit* und der *Transparenz* des Systemverhaltens (vgl. Jameson, 2002). Herlocker, Konstan und Riedl

---

<sup>3</sup>Dynamische Bayes'sche Netze werden in diesem Zusammenhang in Einklang mit Definition 1 als ein maschinelles Lernverfahren interpretiert.

<sup>4</sup>[www.amazon.com](http://www.amazon.com)

<sup>5</sup>[www.yahoo.com](http://www.yahoo.com)

(2000) führen die folgenden Gründe an, die für die Verwendung interpretierbarer Benutzermodelle als Grundlage vorhersagbarer, transparenter Systeme sprechen:

- *Begründung*: Auf der Basis interpretierbarer Modelle kann der Benutzer entscheiden, wieviel Vertrauen er in die Adaptionsentscheidungen des Systems setzt.
- *Einbeziehung des Benutzers*: Durch eine Einbeziehung des Benutzers in den Schlussfolgerungsprozess kann dieser sein Wissen in den Entscheidungsprozess einbringen. Dies ist nur dann möglich, wenn der Benutzer sein Wissen in den Kontext des interpretierbaren Modells einordnen kann.
- *Verständnis*: Versteht der Benutzer den Schlussfolgerungsprozess des Systems, so kann er dessen Stärken und Schwächen erkennen.
- *Akzeptanz*: Aufbauend auf den bisher angeführten Gründen, erhöht sich die Akzeptanz eines benutzeradaptiven Systems mit einem interpretierbaren Benutzermodell, da seine Grenzen und sein Potential erkennbar sind und die Entscheidungen eines solchen Systems begründet werden können.

Diese Gründe spielen in ähnlicher Form nicht nur bei der Anwendung des Benutzermodells sondern auch beim Entwurf und der Konstruktion eines benutzeradaptiven Systems eine wichtige Rolle. Die Verwendung interpretierbarer Benutzermodelle versetzt den Systementwickler in die Lage, Fehler in den Modellen zu lokalisieren und diese gegebenenfalls zu beheben.

Die kausale Interpretation der erlernten Strukturen Bayes'scher Netze eignet sich als Grundlage für Erklärungskomponenten in benutzeradaptiven Systemen (Druzdzel, 1996). Da das Lernproblem Bayes'scher Netze als hochdimensionales Suchproblem mit typischerweise vielen lokalen Optima angesehen werden kann, können Standardverfahren Ergebnisse liefern, die—wenn überhaupt—nur sehr schwer zu interpretieren sind, obwohl sie rein numerisch betrachtet sehr hohe Genauigkeiten bei der Inferenz erzielen können (vgl. Wittig & Jameson, 2000). Die existierenden CPT-Lernverfahren berücksichtigen diese Problematik bisher nur in geringem Maße.

### 3.6 Eigenschaften der Trainingsdaten

Im Wesentlichen können zwei Arten von Trainingsdaten<sup>6</sup> für das maschinelle Lernen von Benutzermodellen unterschieden werden (vgl. Kobsa, Koenemann & Pohl, 2001; Jameson, 2002): (a) solche *expliziten* Charakters, die beispielsweise vom Benutzer selbst z.B. durch Ausfüllen eines Fragebogens oder durch Bewerten von (Test-)Objekten dem System zur Verfügung gestellt werden, und (b) Daten, *impliziten* Charakters, die indirekt, anhand der Interaktionsdaten, unter Anwendung spezieller Verfahren behandelt werden (müssen). Allgemein spricht man in diesem Zusammenhang von (a) *überwachtem* (engl. *supervised*) bzw. (b) *unüberwachtem* (engl. *unsupervised*) maschinellem Lernen. In letztere Kategorie fallen beispielsweise Informationen, die durch eine Analyse der vom Benutzer gekauften Waren oder seines Navigationsverhaltens auf den Web-Seiten des Online-Shops indirekt bestimmt werden können wie etwa seine Interessen. Kobsa et al. (2001) und Jameson (2002) stellen detailliertere Kategorisierungen der in benutzeradaptiven Systemen im Rahmen des Adaptionsprozesses relevanten Datenausprägungen vor.

Insbesondere der zweite Fall ist typisch für die Situation in vielen benutzeradaptiven Systemen. Oft soll eine für den Benutzer aufwendige Befragungsphase vor der eigentlichen Interaktion vermieden werden, um die Hemmschwelle für potentielle Benutzer so gering wie möglich zu halten. Gleichzeitig sind Rückmeldungen über den Erfolg der Adaption in vielen Fällen nicht direkt möglich. Implizite Daten sind naheliegenderweise oft stark mit Unsicherheit behaftet, was von den eingesetzten maschinellen Lernmethoden bei der Modellakquisition berücksichtigt werden sollte.

Ein eng verwandtes Problem in der Benutzermodellierung sind *fehlende Daten* (engl. *missing data*), d.h., unvollständige Datensätze, in denen Werte zu einzelnen Variablen nicht aufgezeichnet wurden. Dieses Fehlen kann unterschiedliche Gründe haben: Oftmals ist es technisch nicht möglich die Daten zu erheben, z.B. durch das Fehlen entsprechender Sensoren. In anderen Fällen ist es prinzipiell unmöglich

---

<sup>6</sup>Im vorliegenden Beitrag wird davon ausgegangen, dass die Trainingsdaten bereits einen Vorverarbeitungsschritt durchlaufen haben, der die erhobenen Daten in einer für die eingesetzten Lernverfahren brauchbaren Form bereitstellt. Eine solche Vorverarbeitung der Daten ist in allen Anwendungsgebieten des maschinellen Lernens—nicht nur in benutzeradaptiven Systemen—von großer Bedeutung für den Erfolg der Verfahren.

die Werte von Variablen zu beobachten, wie dies z.B. bei einer Variablen zur Modellierung der kognitiven Belastung eines Systembenutzers der Fall ist. Man spricht dann von so genannten (für den Lernprozess) *verborgenen Variablen* (engl. *hidden variables*).

Maschinelle Lernverfahren für Bayes'sche Netze sind sehr gut geeignet, um mit mit Unsicherheit behafteten Datensammlungen umzugehen, wie es häufig in benutzeradaptiven Systemen der Fall ist. Daten impliziten Charakters führen im Fall von Klassifikationsproblemen zur Verwendung komplexer *unüberwachter Lernverfahren* (meist im Zusammenspiel mit einem naiven Bayes'schen Klassifizierer, siehe z.B. Mitchell, 1997), stellen aber solange sie in einer Vorverarbeitungsphase angesiedelt sind kein Hindernis dar.

### 3.7 Integration von a priori verfügbarem Wissen

Das Einbringen von verfügbarem A-priori-Wissen bzw. Expertenwissen ist eine nicht nur zur Kompensation fehlender Daten häufig eingesetzte Möglichkeit zur Verbesserung der Ergebnisse eines maschinellen Lernprozesses (siehe z.B. Mitchell, 1997). Auf diese Weise ist es in vielen Fällen möglich, die Menge an Trainingsdaten, die zum Erlernen eines adäquaten Modells benötigt wird, deutlich zu reduzieren. Solche Ansätze bieten sich somit zur Behandlung der Problematik weniger Trainingsdaten an (vgl. Abschnitt 3.1) Zusätzlich erhöht das eingebrachte Vorwissen in den meisten Fällen die Interpretierbarkeit der Resultate im Sinne der Diskussion in Abschnitt 3.5.

Jameson (2002) unterscheidet in diesem Zusammenhang *daten-basierte* sowie *theoretisch-basierte* Ansätze zur Konstruktion der Benutzermodelle. Das Einbringen von A-priori-Wissen in den Lernprozess stellt in dieser Kategorisierung eine Kombination dieser beiden Alternativen dar.

A priori vorhandenes Wissen kann in einem Bayes'schen-Netz-Lernszenario in unterschiedlicher Art und Weise genutzt werden. Dabei spielen im Wesentlichen zwei Aspekte eine Rolle: (a) die kausale Interpretation der Kanten und (b) der Bayes'sche Lernansatz. Anschaulich gesprochen bedeutet der Bayes'sche Lernansatz, dass man eine Vorstellung eines Modells mit einer quantifizierbaren Sicherheit hat und diese Einschätzung dann im Lichte neuer Informationen entsprechend anpasst. Somit stellt der Bayes'sche Ansatz eine natürliche Form der Kombination von A-priori-Wissen und neuer Information im Rahmen eines Lernvorgangs dar.

## 4 Eine integrative Konzeption des maschinellen Lernens Bayes'scher Netze für benutzeradaptive Systeme

Um die im vorangehenden Abschnitt angeführten Vorteile maschineller Lernverfahren Bayes'scher Netze für benutzeradaptive Systeme auszunutzen, sowie die identifizierten Schwächen—zumindest teilweise—auszumerzen, wurde die in diesem Abschnitt vorgestellte Konzeption entworfen, die sowohl existierende Verfahren als auch speziell auf den Benutzermodellierungskontext fokussierte, neu entwickelte Verfahren integriert.

**Überblick** Die in Abbildung 1 schematisch dargestellte Konzeption lässt sich in Bezug auf verschiedene *Dimensionen* charakterisieren, die im Weiteren diskutiert werden. Dabei werden typischerweise von einem potentiellen benutzeradaptiven Zielsystem nur eine eingeschränkte Auswahl der angebotenen Optionen genutzt. Das mit dieser Gesamtkonzeption verfolgte Ziel ist es, eine Sammlung separater anwendbarer Methoden im Sinne des „Werkzeugkastenprinzips“ bereitzustellen, die bei Bedarf ohne Reibungsverluste kombiniert werden können, um die generische Konzeption zu instantiiieren. An dieser Stelle wird für detaillierte Beschreibungen und Evaluationen der (Einzel-)Verfahren zu Gunsten des Gesamtüberblicks verzichtet und auf die entsprechenden Veröffentlichungen (Wittig & Jameson, 2000; Jameson & Wittig, 2001) verwiesen.

**Offline-Lernen und Online-Adaption** Die ersten beiden (in der Abbildung grau unterlegten) Dimensionen sind—in Analogie zur allgemeinen Situation im maschinellen Lernen—das (*Offline-)*Lernen und die (*Online-)*Adaption. Im Verlauf einer Offline-Phase wird üblicherweise ein allgemeines Benutzermodell auf Basis der verfügbaren Daten zu einer Vielzahl von Benutzern erlernt. Dies kann seinerseits als

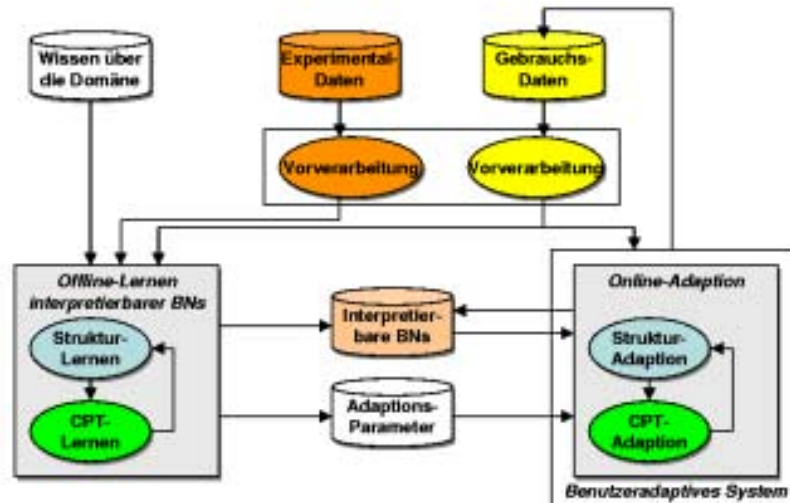


Abbildung 1: Konzeption zum maschinellen Lernen Bayes'scher Netze für benutzeradaptive Systeme

Ausgangspunkt der Interaktion des Zielsystems mit einem neuen Benutzer dienen. Liegen keine Daten anderer Benutzer vor, so muss auf die manuelle Konstruktion (durch Experten) zurückgegriffen werden. Das initiale, allgemeine Bayes'sche Netz wird unter Verwendung entsprechender Adaptionverfahren an den individuellen Benutzer angepasst und kann nach Beendigung der Interaktion für die zukünftige Verwendung mit diesem Nutzer gespeichert werden.

Zusätzlich zum allgemeinen Benutzermodell erhält man aus der Offline-Phase Parameter für den Mechanismus der Adaption an den individuellen Benutzer. Die zugrunde liegende Idee des neu entwickelten Verfahrens der *differentiellen Adaption Bayes'scher Netze* (Jameson & Wittig, 2001) ist, dass unterschiedliche Teile des Bayes'schen Netzes mit unterschiedlicher Geschwindigkeit an den individuellen Benutzer adaptiert werden sollten. Damit kann die Tatsache behandelt werden, dass Benutzer sich in einigen Aspekten weitestgehend ähnlich verhalten, hinsichtlich anderer Eigenschaften oder Verhaltensweisen aber durchaus stark differieren können.

**Experimentelle Daten und Gebrauchsdaten** Zwei weitere Dimensionen der Konzeption betreffen die Art der verwendeten bzw. verfügbaren Lerndaten. Man unterscheidet diesbezüglich zwischen *experimentellen Daten* und *Gebrauchsdaten* (siehe oberer Teil der Abbildung). Experimentelle Daten werden in kontrollierten Umgebungen wie beispielsweise in psychologisch motivierten Experimenten gesammelt. Gebrauchsdaten werden im Rahmen der „echten“ Interaktion zwischen Benutzer und System erhoben. Solche Daten zeichnen sich oft durch unvollständige Datensätze und eine Unterrepräsentation seltener auftretender Situationen aus. Dagegen spiegeln im Rahmen von Experimenten gesammelte Daten häufig nicht adäquat die reale Anwendungssituation wider. Oftmals ist eine Kombination der beiden Datenformen vorhanden. Sie kann mit dem beschriebenen Offline-/Online-Ansatz beispielsweise durch (a) das Lernen eines allgemeinen Benutzermodells anhand experimenteller Daten mit (b) anschließender Adaption auf der Basis von Gebrauchsdaten behandelt werden.

**Lernen der bedingten Wahrscheinlichkeiten und der Struktur** Aufgrund des Aufbaus Bayes'scher Netze bestehend aus zwei Teilkomponenten sind auch die Lern- und Adaptionaufgabe 2-dimensional: (a) das *Lernen bzw. die Adaption der Struktur* und (b) das *Lernen bzw. die Adaption der bedingten Wahrscheinlichkeiten* der CPTs. Um die im vorigen Abschnitt formulierten Probleme zu behandeln, spielt das Einbringen von a priori vorhandenem Wissen eine große Rolle in der vorliegenden Konzeption. Hierbei stehen insbesondere—wegen ihrer entscheidenden Bedeutung für den erfolgreichen Einsatz maschineller Lernverfahren in benutzeradaptiven Systemen—die Verbesserung der Interpretierbarkeit und die Problematik zu weniger Trainingsdaten im Vordergrund des Interesses.

**Grad der Interpretierbarkeit** Wie in Abschnitt 3.5 argumentiert, spielt die Eigenschaft der *Interpretierbarkeit* der erlernten Benutzermodelle in Form der Bayes'schen Netze aus mehreren Gründen eine wichtige Rolle. Diesem Ziel wird in der vorgeschlagenen Konzeption u.a. durch die neu entwickelte *Methode des Lernens mit qualitativen Constraints* (Wittig & Jameson, 2000) zum Einbringen des vorhandenen Domänenwissens Rechnung getragen.

Selbst wenn die Nutzung des A-priori-Wissens keine Verbesserung der Performanz der erlernten Benutzermodelle bewirkt, lohnt sie sich möglicherweise alleine aufgrund der erzielten erhöhten Interpretierbarkeit der Resultate.

## 5 Zusammenfassung und Ausblick

Im vorliegenden Beitrag wurden wichtige Problemstellungen im Zusammenhang mit dem Einsatz maschineller Lernverfahren im Kontext benutzeradaptiver Systeme identifiziert und potentielle Lösungsansätze am Beispiel Bayes'scher Netze diskutiert. Es wurde diesbezüglich ein Überblick über eine integrative Konzeption vorgestellt, die sowohl existierende als auch neu entwickelte, speziell auf den Benutzermodellierungskontext zugeschnittene, Verfahren umfasst.

Inhalt zukünftiger Arbeiten wird im Wesentlichen die weitere Anwendung und Evaluation dieser Konzeption bzw. der zugehörigen Verfahren in verschiedenen Einsatzszenarien sein. Darüberhinaus werden weitere, alternative Verfahren des Lernens bzw. der Adaption Bayes'scher Netze für benutzeradaptive Systeme entwickelt.

### Literatur

- Billsus, D. & Pazzani, M. J. (1999). A hybrid user model for news story classification. In J. Kay (Hrsg.), *UM99, User modeling: Proceedings of the Seventh International Conference* (S. 99–108). Vienna: Springer Wien New York.
- Druzdzal, M. J. (1996). Qualitative verbal explanations in bayesian belief networks. *AISB Quarterly*, 94, 43–54.
- Heckerman, D. (1995). *A tutorial on learning with Bayesian networks* (Tech. Rep. Nr. MSR-TR-95-06). Microsoft Research. (Revised November 1996)
- Herlocker, J. L., Konstan, J. A. & Riedl, J. (2000). Explaining collaborative filtering recommendations. In *Proceedings of the 2000 conference on computer-supported cooperative work*.
- Jameson, A. (2002). Adaptive interfaces and agents. In J. A. Jacko & A. Sears (Hrsg.), *Handbook of human-computer interaction in interactive systems*. Mahwah, NJ: Erlbaum. (In press)
- Jameson, A. & Wittig, F. (2001). Leveraging data about users in general in the learning of individual user models. In B. Nebel (Hrsg.), *Proceedings of the Seventeenth International Joint Conference on Artificial Intelligence* (S. 1185–1192). San Francisco, CA: Morgan Kaufmann.
- Kobsa, A., Koenemann, J. & Pohl, W. (2001). Personalized hypermedia presentation techniques for improving online customer relationships. *The Knowledge Engineering Review*.
- Langley, P. (1997). Machine learning for adaptive interfaces. In G. Brewka, C. Habel & B. Nebel (Hrsg.), *KI-97: Advances in artificial intelligence* (S. 53–62). Berlin: Springer.
- Mitchell, T. M. (1997). *Machine learning*. Boston: McGraw-Hill.
- Olesen, K. G., Lauritzen, S. L. & Jensen, F. V. (1992). aHUGIN: A system creating adaptive causal probabilistic networks. In D. Dubois, M. P. Wellman, B. D'Ambrosio & P. Smets (Hrsg.), *Uncertainty in Artificial Intelligence: Proceedings of the Eighth Conference* (S. 223–229). San Mateo: Morgan Kaufmann.
- Pearl, J. (1988). *Probabilistic reasoning in intelligent systems: Networks of plausible inference*. San Mateo, CA: Morgan Kaufmann.
- Schäfer, R. (1998). *Benutzermodellierung mit dynamischen Bayes'schen Netzen als Grundlage adaptiver Dialogsysteme [User modeling with dynamic Bayesian networks as a foundation for adaptive dialog systems]*. Dissertation, Department of Computer Science, Saarland University, Germany.
- Webb, G., Pazzani, M. J. & Billsus, D. (2001). Machine learning for user modeling. *User Modeling and User-Adapted Interaction*, 11, 19–29.
- Widmer, G. & Kubat, M. (1996). Learning in the presence of concept drift and hidden contexts. *Machine Learning*, 23(1), 69–101.
- Wittig, F. & Jameson, A. (2000). Exploiting qualitative knowledge in the learning of conditional probabilities of Bayesian networks. In C. Boutilier & M. Goldszmidt (Hrsg.), *Uncertainty in Artificial Intelligence: Proceedings of the Sixteenth Conference* (S. 644–652). San Francisco: Morgan Kaufmann.