

# Empirisch basierte Benutzermodellierung mit Bayesschen Netzen: Strukturelle Aspekte

**Frank Wittig**

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

## Zusammenfassung

Auf der Basis empirischer Daten, die im Rahmen eines psychologischen Experiments erhoben wurden, wird eine Analyse alternativer Benutzermodelle in Form dynamischer Bayesscher Netze vorgestellt. Im Vordergrund steht hierbei die Frage, ob und gegebenenfalls wie individuelle Unterschiede zwischen den Versuchspersonen modelliert werden sollten, sowie eine Untersuchung der Auswirkungen der Verwendung von Techniken des maschinellen Lernens zur Ermittlung der Struktur der Bayesschen Netze auf die Performanz der gelernten Benutzermodelle.

## 1 Einleitung

Müller, Großmann-Hutter, Jameson, Rummer und Wittig (2001) stellen eine experimentelle Studie vor, die u. a. die Frage untersucht, ob und gegebenenfalls wie gut es möglich ist, *kognitive Belastung* und *Zeitdruck*, denen eine Person ausgesetzt ist, anhand von Symptomen ihrer gesprochenen Sprache zu erkennen. Dazu wurde ein maschinell gelerntes Benutzermodell in Form eines strukturell recht einfach aufgebauten dynamischen Bayesschen Netzes verwendet, insbesondere wurde auf *erklärende* Variablen verzichtet und das Lernen auf die bedingten Wahrscheinlichkeiten beschränkt. Solche erklärenden Variablen erhöhen die Verständlichkeit des Modells, da sie auf einer zugrundeliegenden theoretischen Motivation basieren. Allerdings sind diese Variablen oft dadurch charakterisiert, dass für sie keine Werte in den zur Verfügung stehenden Lerndaten vorhanden sind und damit die Komplexität der Lernaufgabe erhöht wird. Man spricht in diesem Fall von sogenannten *verborgenen* Variablen, für die spezielle aufwendigere Lernverfahren benötigt werden.

Dieser Beitrag untersucht, ob (a) strukturell komplexere Modelle mit verborgenen erklärenden Variablen, denen eine stärkere theoretische Motivation zugrundeliegt und eine potentiell größere Ausdrucksstärke bzw. Interpretierbarkeit innewohnt, ähnlich gute Resultate liefern wie jenes aus (Müller et al., 2001), und (b) wie die Anwendung von Techniken des maschinellen Lernens zur Ermittlung der Struktur eines Bayesschen Netzes – zusätzlich zum Lernen der bedingten Wahrscheinlichkeiten – die Qualität der Benutzermodelle beeinflusst.

## 2 Experiment

In diesem Abschnitt wird das psychologische Experiment zusammengefasst, das die empirischen Daten für die Analysen dieses Artikels lieferte. Es beschäftigt sich mit den Zu-

sammenhängen zwischen dem (Nicht-)Vorhandensein von Zeitdruck und/oder kognitiver Belastung einerseits und Symptomen gesprochener Sprache andererseits.

Das Experiment bestand aus einer Simulation, in der ein Benutzer eines mobilen Assistenzsystems in einem Flughafenterminal verschiedene Ziele anläuft, während er gleichzeitig per Spracheingabe Anfragen an das System stellt.

Im Wesentlichen bestand die konkrete Situation des Experiments darin, dass die Versuchspersonen auf dem Bildschirm Bilder präsentiert bekamen, anhand derer sie Fragen formulieren sollten. Gleichzeitig mussten sie mit Hilfe der Cursor-Tasten durch ein simuliertes Flughafenterminal navigieren, wobei verschiedene Ziele anzulaufen waren. Die Versuchspersonen wurden in der Hälfte der verschiedenen experimentellen Situationen angewiesen, die Fragen möglichst schnell zu formulieren, d. h. sie wurden unter Zeitdruck gesetzt, in der anderen Hälfte sollten Fragen sowohl hoher inhaltlicher als auch formaler Qualität produziert werden. Eine weitere unabhängige Variable des Experiments bestand in der eine zusätzliche kognitive Belastung induzierenden Navigationsaufgabe: entweder musste durch das simulierte Terminal navigiert werden oder nicht, so dass insgesamt vier verschiedene experimentelle Bedingungen betrachtet wurden. Die Äußerungen der Versuchspersonen wurden aufgezeichnet und auf sprachliche Symptome wie die Anzahl der Silben, das Auftreten stiller bzw. gefüllter Pausen, die Artikulationsgeschwindigkeit und weitere Qualitätssymptome (z. B. Satzabbrüche, Selbstkorrekturen etc.) untersucht. Weiterhin wurde die relative inhaltliche Qualität der Äußerungen von vier Gutachtern bewertet. Insgesamt wurde das Experiment mit 32 Versuchspersonen durchgeführt, die jeweils 80 Äußerungen produzierten.

Die Hauptergebnisse bezüglich des Einflusses von Zeitdruck vs. Qualität bei der Frageformulierung und dem Fehlen bzw. Vorhandensein der Navigationsaufgabe können folgendermaßen zusammengefasst werden:

- *Zeitdruck vs. Qualität:* Unter Zeitdruck tendieren die Versuchspersonen dazu, schneller zu artikulieren und weniger stille Pausen zu machen. Ebenso nimmt sowohl die inhaltliche als auch die formale Qualität ihrer Äußerungen ab.
- *Navigationsaufgabe:* Insgesamt hat die Navigationsaufgabe und die mit ihr induzierte kognitive Belastung wesentlich geringere Auswirkungen auf die sprachlichen Äußerungen der Versuchspersonen als Zeitdruck. Sie waren weitgehend in der Lage, die Qualität ihrer Sprache trotz der Navigationsaufgabe aufrecht zu erhalten<sup>1</sup>.

Eine detaillierte Beschreibung des Aufbaus, eine ausführliche statistische Analyse des Experiments sowie eine Einordnung in die aktuelle verwandte Forschung finden sich bei Müller et al. (2001).

## 3 Benutzermodellierung mit Bayesschen Netzen

### 3.1 Bayessche Netze

Bayessche Netze (BNs) (Pearl, 1988) eignen sich aus zwei Gründen sehr gut für die Anwendung in der Benutzermodellierung: Einerseits sind sie in der Lage mit Unsicherheit in der Domäne umzugehen, eines der charakteristischen Merkmale in der Benutzermodellierung, und andererseits können die gerichteten Kanten eines BNs kausal interpretiert werden, was oft zur einfachen Konstruktion und Interpretierbarkeit eines BN-Benutzermodells beiträgt. Die Interpretierbarkeit eines Benutzermodells ist ein wichtiger

---

<sup>1</sup>Es wäre sehr einfach möglich gewesen, die Navigationsaufgabe schwieriger zu gestalten, möglicherweise bis zu einem Schwierigkeitsgrad, der zum vollständigen Einbruch der Leistung geführt hätte. Das war allerdings nicht das Ziel der Navigationsaufgabe dieses Experiments. Sie sollte eine ähnliche zusätzliche Belastung erzeugen wie diejenige der realen Situation.

Aspekt hinsichtlich der Akzeptanz eines adaptiven Systems seitens seiner Nutzer (s. beispielsweise Cook & Kay, 1994).

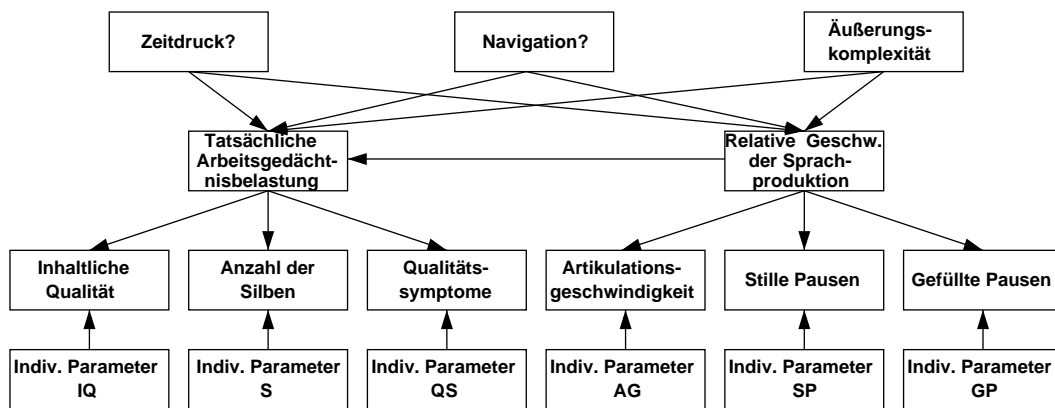


Abbildung 1: BN-Benutzermodell für das Experiment

Abbildung 1 zeigt ein Benutzermodell in Form eines BNs für die Versuchspersonen des im vorigen Abschnitt vorgestellten Experiments, das die Zusammenhänge zwischen den experimentellen Bedingungen und sprachlichen Symptomen der Äußerungen modellieren soll. In der Abbildung oben angeordnet befinden sich die unabhängigen Variablen des Experiments – die zusätzliche unabhängige Variable **ÄUßERUNGSKOMPLEXITÄT** repräsentiert den Komplexitätsgrad der Bilder hinsichtlich der Schwierigkeit der Formulierung einer adäquaten Frage<sup>2</sup>. Alle unabhängigen Variablen haben einen kausalen Einfluss auf die beiden verborgenen erklärenden Variablen **TATSÄCHLICHE ARBEITSGEDÄCHTNISBELASTUNG** und **RELATIVE GESCHWINDIGKEIT DER SPRACHPRODUKTION**. Die Kante zwischen diesen beiden Variablen soll die Hypothese modellieren, dass es den Versuchspersonen möglich ist, die kognitive Belastung durch eine Reduzierung der Geschwindigkeit der Sprachproduktion zu vermindern. Die Sprachsymptome wurden in zwei Gruppen kategorisiert: (a) arbeitsgedächtnis-abhängige und (b) sprachproduktions-abhängige. Zusätzlich existiert für jedes Symptom eine sog. *individuelle Parametervariable*, die die allgemeine Tendenz der Versuchsperson hinsichtlich des entsprechenden Symptoms charakterisiert, z. B. sprechen manche Personen üblicherweise sehr schnell, andere jedoch sprechen sehr langsam. Die Werte dieser Parametervariablen können auf der Basis der Durchschnittswerte der entsprechenden Symptomvariablen der einzelnen Versuchspersonen bestimmt werden.

Um explizit dynamische Aspekte einer mit Unsicherheit behafteten Domäne zu modellieren, können *dynamische BNs* (DBNs) verwendet werden. Sie bestehen aus (a) sogenannten *Zeitscheiben*, die diskrete Zeitpunkte repräsentieren, und (b) probabilistischen Übergangsinformationen zwischen zwei aufeinanderfolgenden Zeitscheiben. In DBNs können *statische*, *dynamische* und *temporäre* Variablen modelliert werden. Abbildung 1 stellt beispielsweise eine solche Zeitscheibe für eine einzelne Äußerung einer Versuchsperson in einer bestimmten experimentellen Situation dar. Aufeinanderfolgende Äußerungen werden durch Aneinanderhängen von Zeitscheiben modelliert. **ZEITDRUCK?** und **NAVIGATION?** sind in diesem Fall statische Variablen, d. h. ihr “echter” Wert – die vorliegende experimentelle Bedingung – ändert sich während der Lebensdauer des DBNs nicht. Von diesen statischen Variablen existiert jeweils nur eine Instanz, die ausgehende Kanten zu ihren direkten temporären Nachfolgevariablen **TATSÄCHLICHE ARBEITSGEDÄCHTNISBELASTUNG** und **RELATIVE GESCHWINDIGKEIT DER SPRACH-**

<sup>2</sup>Zur Bestimmung der Werte der einzelnen Bilder für diese Variable wurden die Bilder unabhängigen Gutachtern vorgelegt, die sie entsprechenden Schwierigkeitsklassen zuteilten.

PRODUKTION in allen Zeitscheiben besitzen. Damit ist es möglich, auf der Basis beobachteter Sprachsymptome Rückschlüsse über die experimentelle Bedingung zu ziehen, in der sie entstanden sind. Dazu werden die Symptomvariablen mit den in der betrachteten Äußerung beobachteten Werten, die Parametervariablen mit den entsprechenden Werten der Versuchsperson und die ÄUßERUNGSKOMPLEXITÄT mit der dem Bild zugeordneten Bewertung instantiiert und mittels der Inferenzverfahren für BNs die neuen resultierenden Wahrscheinlichkeits-Werte für die beiden statischen Variablen zur Modellierung der Experimentalbedingung ermittelt (s. Schäfer und Weyrath (1997) für eine ausführliche Diskussion der Verwendung DBNs in der Benutzermodellierung).

### 3.2 Lernen Bayesscher Netze

Soll nun ein BN anhand empirischer Daten maschinell gelernt werden, müssen sowohl die den Kanten zugeordneten Tabellen der bedingten Wahrscheinlichkeiten (engl. conditional probability tables, CPTs) als auch die Struktur des BNs gelernt werden. Mit dem ersten Teil der Aufgabe im Kontext des Lernens interpretierbarer Benutzermodelle beschäftigen sich Wittig und Jameson (2000). Der Fokus des vorliegenden Artikels hinsichtlich des Lernproblems und seiner Auswirkungen auf die Performanz des Benutzermodells liegt auf dem strukturellen Aspekt.

In der folgenden Studie wird zum Lernen der CPTs der *EM-Algorithmus (Expectation-Maximization)* von Dempster, Laird und Rubin (1977) verwendet. Zum strukturellen Lernen wird der hybride *SEM-Algorithmus (structural EM)* von Friedman (1998) benutzt, der zwischen einer Greedy-Suchstrategie im Raum der Strukturen und dem EM-Algorithmus zum Lernen der CPTs alterniert bis ein (lokales) Optimum des BIC-Qualitätsmaßes (*Bayesian Information Criterion*, s. Schwarz, 1978) erreicht wird. Im wesentlichen beschreibt dieses Qualitätsmaß einen Tradeoff zwischen der Genauigkeit und der Komplexität des gelernten BNs. Der Grund, um komplexere Strukturen während des Lernens durch schlechtere Bewertungen zu "bestrafen", liegt u. a. in der allgemeinen Erfahrung im maschinellen Lernen, dass solche Modelle zu stärkerem *Overfitting*, d. h. zu einer Spezialisierung bezüglich der verwendeten Lerndaten neigen und hinsichtlich neuer Daten schlechtere Ergebnisse liefern.

## 4 Empirische Analyse

Nachfolgend werden die Auswirkungen unterschiedlicher Modellierungen des Verhaltens der Versuchspersonen mit BNs untersucht. Dabei spielen insbesondere mittels der vorgestellten Techniken gelernte Strukturen der BNs eine wichtige Rolle. Die Untersuchungen dieses Abschnitts können somit als eine Ergänzung bzw. Erweiterung der in (Müller et al., 2001) vorgestellten Analysen angesehen werden. Insbesondere spielt hier die Interpretierbarkeit der Modelle eine bedeutendere Rolle, da die Struktur der BNs um die beiden erklärenden verborgenen Variablen TATSÄCHLICHE ARBEITSGEDÄCHTNISBELASTUNG und RELATIVE GESCHWINDIGKEIT DER SPRACHPRODUKTION ergänzt wurde<sup>3</sup>. Die Auswirkungen der damit verbundenen erhöhten Schwierigkeit des Lernproblems wird ebenfalls diskutiert.

---

<sup>3</sup>Ein weiterer Grund zur Verwendung der beiden Variablen besteht in der Verwendung ihrer Werte im Rahmen entscheidungstheoretischer Planung zur benutzer-adaptiven Informationspräsentation (s. Bohnenberger (2001)).

## 4.1 Verfahren

Die untersuchten strukturellen Varianten des Benutzermodells, die als alternative Zeitscheiben der DBNs dienten, wurden entweder von Hand auf der Basis entsprechender theoretischer Überlegungen spezifiziert (vgl. Abschnitt 3) oder durch Anwendung des SEM-Algorithmus auf die Daten des Experiments gelernt<sup>4</sup>.

Zur Bewertung der Güte der unterschiedlichen untersuchten Varianten des Benutzermodells wurde jeweils eine *leave-one-out-Kreuzvalidierung* durchgeführt, d. h. es wurde ein allgemeines Modell auf der Basis der Daten von 31 Versuchspersonen gelernt, das dann mit Hilfe der Daten der verbleibenden 32. Versuchsperson durch eine sequentielle Verarbeitung im DBN evaluiert wurde. Präsentiert werden die durchschnittlichen Werte aller Kombinationen von Lern- und Testdaten. Dazu wurden mit Hilfe des jeweiligen DBNs die Wahrscheinlichkeiten der vier unterschiedlichen experimentellen Konfigurationen (Zeitdruck: nicht vorhanden / vorhanden, Navigationsaufgabe: nicht vorhanden / vorhanden) wie in Abschnitt 3 beschrieben separat betrachtet. Eine detailliertere Beschreibung der Vorgehensweise findet sich in (Müller et al., 2001).

## 4.2 Ergebnisse

### 4.2.1 Allgemeines

Abbildung 2 zeigt die Ergebnisse – je eine separate Kurve für jede experimentelle Teilbedingung – für die Analyse unter Verwendung der Struktur aus Abbildung 1 als Zeitscheibe. Man sieht, dass beispielsweise Zeitdruck am besten erkannt wird, wenn keine Navigationsaufgabe bewältigt werden musste. Am schwierigsten ist es für das System das Vorhandensein der Navigationsaufgabe zu erkennen, wenn qualitativ hochwertige Äußerungen gefordert wurden, also kein Zeitdruck vorlag. Insgesamt hat man eine recht gute Erkennung von Zeitdruck bzw. keinem Zeitdruck, wo schon nach wenigen Äußerungen Wahrscheinlichkeiten zwischen 70 und 80 Prozent für die korrekte experimentelle Teilbedingung erreicht werden. Die Navigationsaufgabe bereitet dem System mehr Probleme, aber auch hier werden immerhin noch Werte um die 60 Prozent erzielt.

### 4.2.2 Ohne vs. mit individuellen Parametern

Eine Frage, die sich stellt, ist in wie weit sich die individuellen Parameter auf die Performanz des Modells auswirken. Lohnt es sich tatsächlich sie in das Modell einzubringen und ihre Werte pro Versuchsperson zu ermitteln oder genügt es sich mit einem weniger komplexen Modell ohne sie zu begnügen, das dann einfacher und schneller gelernt werden kann, da die Anzahl der zu lernenden bedingten Wahrscheinlichkeiten sowie der Suchraum im Fall strukturellen Lernens eingeschränkt wird?

Abbildung 3 zeigt den Vergleich der beiden genannten Modelle gemittelt über alle Teilbedingungen des Experiments. Es zeigt sich eine deutliche Überlegenheit des Benutzermodells, das individuelle Unterschiede zwischen den Versuchspersonen explizit berücksichtigt. Dies ist leicht zu erklären, wenn man bedenkt, dass es beispielsweise bekanntermaßen große Unterschiede in der Artikulationsgeschwindigkeit verschiedener Personen gibt. Ist z. B. bekannt, dass eine Versuchsperson im allgemeinen relativ langsam

---

<sup>4</sup>Wegen der hohen Komplexität des Lernens von BNs mit verborgenen Variablen wurde auf die Integration der Strukturlernphase in die im folgenden vorgestellte Kreuzvalidierung verzichtet und in Form eines einmaligen Vorverarbeitungsschrittes ausgegliedert. Ergebnisse aus früheren Studien (s. Wittig (2001)) deuten darauf hin, dass es kaum Unterschiede während der Kreuzvalidierung zwischen den gelernten Strukturen gibt. Die Phase des Lernens der CPTs blieb ein Bestandteil der Kreuzvalidierung.




Abbildung 2: Erkennungsleistung bezüglich Zeitdruck und Navigationsaufgabe  
(Die eingeschätzte experimentelle Teilbedingung ist jeweils durch Großbuchstaben gekennzeichnet.)

spricht, dann kann das Modell im Falle einer beobachteten hohen Artikulationsgeschwindigkeit leichter Rückschlüsse bezüglich einer potentiell erhöhten kognitiven Belastung durch das Vorhandensein der Navigationsaufgabe ziehen.

### 4.2.3 Strukturell gelernt vs. manuell spezifizierte Struktur

Die Anwendung des SEM-Algorithmus auf die Struktur aus Abbildung 1 ohne individuelle Parameter liefert als Resultat das Netz aus Abbildung 4. Es enthält zusätzliche Kanten von ÄUßERUNGSKOMPLEXITÄT nach INHALTLICHE QUALITÄT und von ZEITDRUCK? zu QUALITÄTSSYMPTOME?. Weiterhin wurde die Kante von NAVIGATION? nach TATSÄCHLICHE ARBEITSGDÄCHTNISBELASTUNG im Verlauf der Lernprozedur entfernt. Dieser Effekt der Isolation der Variable NAVIGATION? wird sogar noch verstärkt, wenn mit individuellen Parametern gelernt wird: In diesem Fall wird die Kante von ZEITDRUCK? nach RELATIVE GESCHWINDIGKEIT DER SPRACHPRODUKTION zusätzlich gelöscht<sup>5</sup>.

Betrachtet man in Abbildung 5 die Ergebnisse unter Verwendung der Struktur aus Abbildung 4 als Basis der Zeitscheiben des DBNs, so erkennt man, dass sich hier der Tradeoff zwischen Komplexität und Genauigkeit in der vom SEM-Algorithmus verwendeten Bewertungsfunktion auswirkt. Die Genauigkeit bezüglich der Navigationsaufgabe wird zu Gunsten der geringeren Komplexität des Modells durch Entfernen der entsprechenden relevanten Kanten “geopfert”. Andererseits kann wiederum die Erkennung der Qualitäts- bzw. Zeitdruckbedingung durch das Hinzufügen von Kanten durch das Lernverfahren verbessert werden. Insgesamt sind die Einflüsse der Variable NAVIGATION? auf die sprachlichen Symptome zu gering als dass sie zu einer Verbesserungen des Modells im Sinne des Komplexitäts-Genauigkeits-Tradeoffs beitragen könnten. Dies korrespondiert auch mit den Ergebnisse der traditionellen statistischen Analyse des Experiments (s. Müller et al. (2001)).

<sup>5</sup>Eine weitere interessante Beobachtung, die in diesem Fall gemacht wird, sind viele zusätzlich eingefügte Kanten zwischen den individuellen Parametervariablen. Für eine ausführliche Diskussion dieses Effekts wird auf Wittig (2001) verwiesen.




Abbildung 3: Vergleich der durchschnittlichen Erkennungsleistung mit und ohne individuellen Parametern

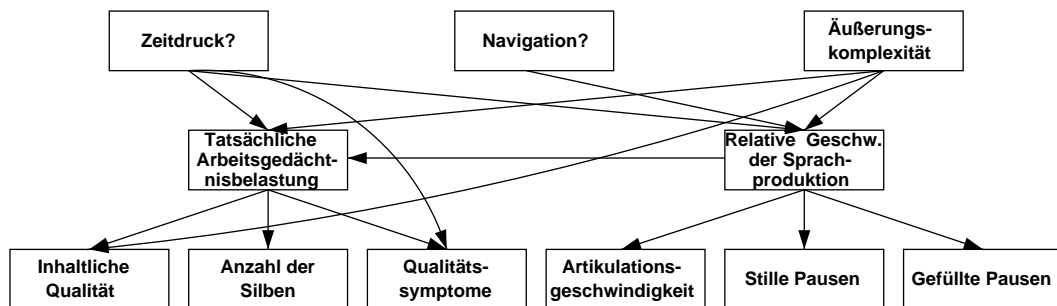


Abbildung 4: Gelerntes BN-Benutzermodell (ohne individuelle Parameter)

## 5 Zusammenfassung und Ausblick

In der vorgestellten Studie liefert die manuell auf der Basis theoretischer Überlegungen festgelegte Struktur bereits ein recht gutes Modell. Dennoch können durch Anwendung der maschinellen Lernverfahren wichtige (eventuell problematische) Aspekte des Modells erkannt und gegebenenfalls näher untersucht und ausgenutzt werden, z. B. die schwachen Einflüsse der Navigationsbedingung und die Zusammenhänge zwischen den individuellen Parametern, die nicht im Fokus dieses Beitrags standen.

Insgesamt liefern die hier verwendeten Modelle mit den beiden erklärenden Variablen qualitativ ähnliche Ergebnisse zum einfacheren Modell aus (Müller et al., 2001). Dies ist insbesondere hinsichtlich des potentiellen Mehrwertes eines benutzer-adaptiven Systems mit interpretierbarem Benutzermodell interessant.

Eine Fragestellung, die die verbesserte Performanz durch die Berücksichtigung individueller Unterschiede durch Parametervariablen betrifft und in weiteren Arbeiten näher untersucht werden soll, ist die Situation, in der die Unterschiede zwischen den einzelnen Benutzern auch die Struktur des Modells – nicht nur die Werte für die Parametervariablen – betreffen. Beispielsweise könnte so etwas relevant sein, wenn sowohl für junge als auch für ältere Personen adäquate Benutzermodelle konstruiert werden sollen. Möglicherweise würden in diesem Fall strukturell unterschiedliche Modelle die einzelnen Benutzergruppen besser modellieren als ein einziges Modell mit Parametervariablen.

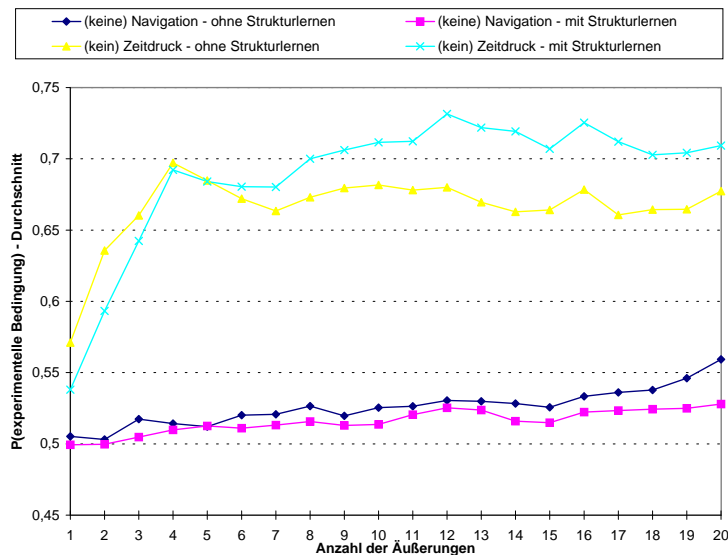


Abbildung 5: Vergleich der durchschnittlichen Erkennungsleistung mit und ohne strukturellem Lernen (ohne individuelle Parameter)

## Danksagung

Diese Arbeit wurde von der Deutschen Forschungsgemeinschaft (DFG) im Rahmen des Sonderforschungsbereichs 378 “Ressourcenadaptive kognitive Prozesse”, SFB 378, Projekt B2 (READY, <http://w5.cs.uni-sb.de/~ready>) gefördert. Das in Abschnitt 2 beschriebene Experiment wurde als Diplomarbeit von Christian Müller unter Mitarbeit von – in alphabetischer Reihenfolge – Sylvia Bach, Barbara Großmann-Hutter, Anthony Jameson, Tore Knabe und Ralf Rummer durchgeführt.

## Literatur

- Bohnenberger, T. (2001). Dialog strategies for adaptive help systems. In N. Henze (Hrsg.), *ABIS2001: GI-Workshop “Adaptivität und Benutzermodellierung”*. Dortmund.
- Cook, R. & Kay, J. (1994). The justified user model: A viewable, explained user model. In A. Kobsa & D. Litman (Hrsg.), *UM94, User Modeling: Proceedings of the Fourth International Conference* (S. 145–150). Boston, MA: User Modeling, Inc.
- Dempster, A. P., Laird, N. M. & Rubin, D. B. (1977). Maximum likelihood from incomplete data via the EM algorithm. *Journal of the Royal Statistical Society*, 39, 1–38.
- Friedman, N. (1998). The bayesian structural EM algorithm. In G. F. Cooper & S. Morales (Hrsg.), *Uncertainty in Artificial Intelligence: Proceedings of the Fourteenth Conference* (S. 129–138). San Francisco: Morgan Kaufmann.
- Müller, C., Großmann-Hutter, B., Jameson, A., Rummer, R. & Wittig, F. (2001). Recognizing time pressure and cognitive load on the basis of speech: An experimental study. In J. Vassileva, P. Gmytrasiewicz & M. Bauer (Hrsg.), *UM2001, User Modeling: Proceedings of the Eighth International Conference*. Berlin: Springer.
- Pearl, J. (1988). *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference*. San Mateo, CA: Morgan Kaufmann.
- Schäfer, R. & Weyrath, T. (1997). Assessing temporally variable user properties with dynamic Bayesian networks. In A. Jameson, C. Paris & C. Tasso (Hrsg.), *User modeling: Proceedings of the Sixth International Conference, UM97* (S. 377–388). Vienna: Springer Wien New York.
- Schwarz, G. (1978). Estimating the dimension of a model. *Annals in Statistics*, 6, 461–464.
- Wittig, F. (2001). Some issues in the learning of accurate, interpretable user models from sparse data. In R. Schäfer, M. E. Müller & S. A. Macskassy (Hrsg.), *Proceedings of the UM2001-Workshop on “Machine Learning for User Modeling”* (S. 11–21). Sonthofen.
- Wittig, F. & Jameson, A. (2000). Exploiting qualitative background knowledge in Bayesian network learning algorithms. In C. Boutilier & M. Goldszmidt (Hrsg.), *Uncertainty in Artificial Intelligence: Proceedings of the Sixteenth Conference* (S. 644–652). San Francisco: Morgan Kaufmann.