

# Unsicherheitsmanagement im Studierenden Modell

## Abstract

*In recent years the use of Intelligent tutoring systems (ITS) has become more and more established in education. As ITS are based on individualized student models, uncertainty management has a key role in designing and updating student models. This paper reviews the design of student models and gives an overview of some of the most important approaches in uncertainty management. The approaches are based on probability theory as well as on educational psychology. A more detailed survey of uncertainty management with Bayesian Networks and an example are provided. Findings about current ITS distribution and topics for further research are referenced. This paper is written for an general academic audience and therefore it focus on main principles and avoids detailed mathematical notation.*

## 1 Einleitung

Nachdem bereits in den frühen 1960er Jahren die ersten Experimente mit Computern im Lehr- und Lernprozess durchgeführt wurden, schuf insbesondere der technische Fortschritt in den folgenden Jahren die Grundlage für einen breiteren Einsatz [2]. So wurde die Entwicklung von *Computer-assisted instructions (CAI)* voran getrieben, die je nach Aufgabe und Fehler vordefiniertes Feedback an die Student\*innen lieferten. Zur selben Zeit wurden Forschungsergebnisse in der Schulpsychologie veröffentlicht, denen zufolge sorgfältig entwickelter und individualisierter Privatunterricht für die meisten Menschen die besten Ergebnisse erzielt. Deshalb werden seit den 1970ern intelligente Tutorium Systeme (eng. *Intelligent tutoring systems (ITS)*) nach dem Vorbild von individualisiertem Privatunterricht entwickelt [15].

Im Studierenden Modell eines ITS wird der Fortschritt und Wissensstand einer Student\*in im Studierenden Modell gespeichert. Bei der Initialisierung und Aktualisierung des Studierenden Modells wird mit dem Unsicherheitsmanagement die Unsicherheit des Systems, insbesondere bei der Erfassung des Wissensstands und bei Prognosen über die Fähigkeit eine Aufgabe korrekt zu lösen, verwaltet [7] [10].

In Abschnitt 2 wird in Studierenden Modelle eingeführt und ein Überblick über die wichtigsten Modell-Varianten gegeben. Anschließend werden in Abschnitt 3 einige der wichtigsten theoretischen Ansätze im Unsicherheitsmanagement und in Abschnitt 3.5 eine detailliertere Betrachtung von Bayesschen Netzen inklusive eines Beispiels vorgestellt. Eine kurzes Fazit inklusive einen Ausblick über weitere Forschungsgebiete wird in Abschnitt 4 gezogen.

## 2 Studierenden Modell

Ein Studierenden Modell wird die Komponente in ITS genannt, die den aktuellen Stand von Wissen und Fähigkeiten jede Student\*in repräsentiert. Das ITS kann dann auf Basis des jeweiligen Modells individuell mit jede Student\*in interagieren. Für jede Student\*in wird ein neues Studierenden Modell erstellt, dass auf einem Prototyp basiert. Bei der Definition eines Prototyps muss die Initialisierung und die Vorgehensweise bei der Aktualisierung des Modells festgelegt werden. Für den Detailgrad des Modells und seiner Elemente sollte eine untere Schranke gewählt werden, die eine angemessene Präzision gewährleistet. Für die obere Schranke hingegen wird die Komplexität durch die Anforderungen des ITS an die Präzision des Studierenden Modells begrenzt [10].

## 2.1 Modellierung von Wissen und Fähigkeiten

Traditionelle Studierenden Modelle modellieren vor allem das aktuelle Wissen der Student\*in mit Variablen. In Abgrenzung zur Überbetonung dieser Merkmale führt Self 1994 [13] Kategorien für Variablen ein, die sich auf die Fähigkeiten der Student\*innen beziehen. Diese werden von Self wie folgt voneinander abgegrenzt. Wissen über intellektuelle Fähigkeiten der Student\*in wird nach Self in Variablen modelliert, die der Kategorie **kognitive Fähigkeiten** zugeordnet werden. Diese Kategorie umfasst unter anderem Variablen, die die Wahrnehmung der Student\*in wie beispielsweise visuelle Intelligenz modelliert. In **konative Fähigkeiten** hingegen werden Merkmale modelliert, die auf Absichten und Ziele, sowie Lerntypen hinweisen. So kann nach Self mit Variablen dieser Kategorie beispielsweise modelliert werden, ob eine Student\*in eher eine nachdenkliche oder impulsive Lernstrategie verfolgt. Merkmale die Werte, Motivation und Emotionen der Student\*innen modellieren werden nach Self in der Kategorie **affektive Fähigkeiten** zusammengefasst. Dies umfasst beispielsweise Annahmen des ITS über das Selbstbild, dass die Student\*in über sich hat.

Alle Informationen über die Student\*innen und ihren Lernfortschritt werden in einem speziellen Modell zur Repräsentation des Wissens und der Fähigkeiten der Student\*in gespeichert [10]. Da sich die technische Modellierung von Wissen und Fähigkeiten nicht unterscheidet und sich einige Ansätze auf die Modellierung von Wissen beschränken, wird im weiteren Verlauf dieser Zusammenfassung verallgemeinernd von der Modellierung von Wissensständen gesprochen. Bei der Modellierung und Bewertung ist Unsicherheit ein zentraler Aspekt. Für ein Unsicherheitsmanagement wird daher bei der Modellierung von Wissensstände auf Ansätze der Wahrscheinlichkeitstheorie zurückgegriffen [6]. Die unterschiedlichen Ansätze werden in Abschnitt 3 ausführlich vorgestellt.

## 2.2 Varianten der Studierenden Modelle

Die folgenden weit verbreiten Ansätze für Studierenden Modelle bilden die Grundlage für verschiedene Lösungsansätze.

Das **overlay model** betrachtet den Wissensstand der Student\*in als Teilmenge des gesamten verfügbaren Wissens des ITS [10] und geht zurück auf Carbonell's Eingabe-Ausgabe Modell von 1970 [4]. In diesem Modell wird der Wissensstand der Student\*in mit dem Wissensstand einer fiktiven, perfekten Student\*in verglichen. Abweichendes Verhalten der Student\*in wird als Hinweis auf eine Wissenslücke interpretiert. Allerdings erkennt das System falsche Grundannahmen nicht und ist daher nicht in der Lage diese zu korrigieren [10].

Das **Bedingungs-basierte Modell (CBM)** (eng. *Constraint-Based Model*) wurde 1992 von Stellan Ohlsson entwickelt. Deklaratives Wissen wird bei diesem Ansatz in einer Menge von Bedingungen anstatt in Variablen, Aussagen oder Schemata gespeichert. Ein Mechanismus nutzt Bedingungen, um Fehler während des Lernprozesses zu erkennen ohne dafür vorher ein bestimmtes Szenario oder einen speziellen Generator angelegt zu haben. Ein ITS kann so um eine Wissensbasis aus Bedingungen aufgebaut werden, dass hilfreiches Feedback selbst für ungewöhnliche Lösungsansätze geliefert wird [12]. Das CBM ist die Grundlage für Bedingungs-basierte Tutoren (eng. *Constraint-based tutors*) und kann in Verbindung mit verschiedenen Ansätzen des Unsicherheitsmanagements wie Bayessche Netze, Probabilistische Testtheorie, oder model tracing eingesetzt werden [11].

Beim **knowledge/model tracing** nach Anderson et al. 1995 [1] und Koedinger et al. 1997 [8] wird grundsätzlich zwischen dem Ansatz zur Bewertung durch knowledge tracing und dem Ansatz zur Planerkennung durch model tracing unterschieden [10]. Nach Anderson et al. 1995 [1] wird beim **knowledge tracing** der Wissensstand der Student\*in anhand der Korrektheit einer gelösten Aufgabe bewertet. Durch die interne Verknüpfung einer Aufgabe mit für die Lösung notwendigen Grundkenntnissen und Regeln werden Aussagen über den Wissensstand der Student\*in getroffen. Anhand der Erkenntnisse über notwendige zugrundeliegende Regeln für den Lösungsweg einer Aufgabe kann eine Vorhersage über den Erfolg der Student\*in bei der Aufgabe erfolgen [1]. Die Auswahl der nächsten Aufgabe kann so individualisiert werden [8]. Beim **model tracing** nach Koedinger et al. 1997 [8] hingegen wird nach jeder erfassbaren Interaktion nachvollzogen welchen Lösungsweg die Student\*in wählt. Dieser Ansatz basiert auf Planerkennung und ist beispielsweise für je nach Lösungsweg individualisierte Hinweise hilfreich, wenn die Student\*in nicht weiter weiß [8], [10], [7].

### 3 Unsicherheitsmanagement im Studierenden Modell

Unsicherheit ist ein zentraler Aspekt bei der Modellierung und Bewertung von Wissensständen im Studierenden Modell [6]. Dabei stehen die Abhängigkeiten zwischen Wissensstand aus dem Studierenden Modell und den Aufgaben im Vordergrund. Selbst wenn die bedingten Abhängigkeiten in einem Modell sehr präzise entwickelt wurden, kann nach Baker et. al 2008 [3] ein Ergebnis immer noch durch einen *slip* (dt. Ausrutscher) oder einen *guess* (dt. [korrekte] Vermutung) verzerrt werden, wodurch sich die Unsicherheit erhöht.

In den folgenden Absätzen werden einige der wichtigsten theoretischen Ansätze zum Unsicherheitsmanagement im Studierenden Modell vorgestellt und auf Bayessche Netze detailliert eingegangen.

#### 3.1 Evidenztheorie von Dempster und Shafer (DST)

In der Evidenztheorie von Dempster und Shafer (DST) (eng. *Dempster-Shafer Theory*) wird die Glaubwürdigkeit der Informationsquellen in die Berechnung mit einbezogen und Wissen aus unterschiedlichen Quellen zu einer Gesamtaussage zusammengesetzt [14]. Ein typischer Fall für den Einsatz eines DST Ansatzes liegt vor, wenn einige der Informationen aus unterschiedlich vertrauenswürdigen oder aussagekräftigen Quellen kommen. So kann beispielsweise eine Selbsteinschätzung einer Student\*in als aussagekräftiger als die Einschätzung einer Lehrkraft über den Wissensstand der Student\*in berücksichtigt werden [7].

#### 3.2 Fuzzylogik (FL)

Fuzzylogik (FL) (eng. *Fuzzy Logic*) wird als Theorie zur Erfassung des Unpräzisen bezeichnet. Sie basiert auf unscharfen Mengen, die durch den Grad der Zugehörigkeit ihrer Elemente definiert sind. Ein Anwendungsfall von FL im Unsicherheitsmanagement in Studierenden Modellen ist beispielsweise wenn aufgrund mangelnder Erfahrung in einem Themengebiet eine ungenaue und relativierende Aussage über den erwarteten Erfolg einer dritte Person bei einer Aufgabe modelliert werden soll. In einem anderen Anwendungsfall ist das Unsicherheitsmanagement durch FL in der Lage eine unpräzise Selbsteinschätzung abzubilden. In beiden unterschiedlichen Fällen ist FL besonders geeignet die ungenaue Aussage abzubilden [7].

#### 3.3 Probabilistische Testtheorie (IRT)

Die Probabilistische Testtheorie (IRT) (eng. *Item Response Theory*) ist ein über mehr als 40 Jahre erforschter Ansatz in der Psychometrie. Bei dem IRT Ansatz für Unsicherheitsmanagement in Studierenden Modellen wird aus jedem sichtbaren Ergebnis, wie dem Erfolg bei der Lösung einer Aufgabe, über eine Funktion genau eine unsichtbare, latente Kompetenz aktualisiert. Für jede Aufgabe werden für die Funktion die Parameter der Schwierigkeitsgrads der Aufgabe und der Selektionsgrad definiert. Der Selektionsgrad gibt die Abhängigkeit des Wissensstands der Student\*in zur Wahrscheinlichkeit des Erfolgs beim Lösen der Aufgabe an. Die Grundidee der IRT ist, dass die Wahrscheinlichkeit der Lösung einer Aufgabe mit dem Wert der latenten, unsichtbaren Kompetenz steigt. Da IRT in der Standardform ein Modell mit genau einer Kompetenz ist, ist es ungeeignet für eine kleinteilige, kognitive Diagnosen [6]. Allerdings haben Millán et. al 2002 [9] einen IRT Ansatz entwickelt, mit dem sie zugrundeliegende Teilkonzepte in eine hierarchische Struktur modelliert haben. So kann die Fähigkeit der Student\*in das Hauptkonzept zu verstehen mit einer detaillierten Bewertung prognostiziert werden. Die IRT wird auch in Abstraktionen und Kombinationen mit anderen Ansätzen des Unsicherheitsmanagements eingesetzt. So sind beispielsweise in einigen Systemen die bedingten Wahrscheinlichkeiten in Bayesschen Netzen an die IRT angelehnt [7].

#### 3.4 Latente Modelle NIDA und NIDO

Mit Noisy Input Deterministic And (NIDA) und Noisy Input Deterministic Or (NIDO) wurden in der Psychometrie neue Ansätze der latenten Modelle entwickelt. Die grundlegende Idee ist, dass jede Aufgabe mehreren latenten Kompetenzen und jede latente Kompetenz mehreren Aufgaben zugeordnet wird.

Für die Verknüpfung zwischen Aufgaben und latenten Kompetenzen wird eine Q-Matrix definiert, die auf dem Regelraum von Tatsuoka 1983 [17] basiert. Die Zeilen der Matrix repräsentieren die Aufgaben und die Spalten die Kompetenzen. Diese Q-Matrizen verbinden Kompetenzen mit Aufgaben. Bei dem NIDA Modell werden verschiedene Kompetenzen benötigt und sie müssen für eine positive Prognose alle erfüllt sein. Deshalb gehört das NIDA Modell zu den *konjunktiven* Modellen. Das NIDO Modell ist der Gegenentwurf zum NIDA. Bei dem NIDO reicht eine Kompetenz für eine positive Prognose. NIDO gehört daher zu den *kompensatorischen* Modellen. Bei NIDA und NIDO werden außerdem von den Kompetenzen abhängige Wahrscheinlichkeitswerte für *slip* und *guess* berücksichtigt [6].

### 3.5 Bayessches Netz (BN)

Ein Bayessches Netz (BN) (eng. *Bayesian Network*) ist eine der am weitest verbreitetsten Möglichkeiten des Unsicherheitsmanagements für Studierenden Modelle [7] [5] [10] [6]. Das liegt insbesondere daran, dass Bayessche Netze eine theoretisch fundierte Grundstruktur aus der Wahrscheinlichkeitstheorie sind und durch den technischen Fortschritt in der Hardware die Ausführung von Inferenzalgorithmen in akzeptabler Zeit möglich ist. Hinzu kommt, dass für BNs einige robuste Bibliotheken bereitstehen, die in Studierenden Modelle eingefügt werden können [10]. Die Darstellung von Wissensständen und Abhängigkeiten ist in Bayesschen Netzen intuitiv und hoch flexibel [6]. Aus diesen Gründen werden in diesem Abschnitt Bayessche Netze ausführlicher als die vorangegangenen Ansätze vorgestellt.

Das Bayessche Netz ist ein gerichteter, kreisfreier Graph mit Knoten für Zufallsvariablen und Kanten für bedingte Abhängigkeiten zwischen den Zufallsvariablen. Jeder Variable ist eine bedingte Wahrscheinlichkeitsverteilung zugewiesen mit der die Variable mit einer Wahrscheinlichkeitstabelle ihren Elternknoten zugeordnet wird. Die bedingte Unabhängigkeitsannahme setzt voraus, dass jede Variable nur von den Variablen ihrer Elternknoten und Kindknoten abhängig ist. Wenn die bedingte Unabhängigkeitsannahme für ein Bayessches Netz erfüllt ist, dann kann die gemeinsame Wahrscheinlichkeitsverteilung berechnet werden, indem die bedingten Wahrscheinlichkeiten jeder Variable unter Bedingung ihrer Elternvariablen multipliziert werden. Für die Initialisierung eines Bayesschen Netzes reicht es bei erfüllter bedingter Unabhängigkeitsannahme deshalb jedem Wurzelknoten eine A-priori-Wahrscheinlichkeitsverteilung und jedem Nicht-Wurzelknoten eine eine bedingte Wahrscheinlichkeitsverteilung abhängig von den Variablen der Elternknoten zuzuweisen [10].

Bayessche Netze sind in der Theorie besonders gut geeignet, um die Wahrscheinlichkeit unsichtbarer Knoten mittels Hinweise aus sichtbaren Knoten abzuleiten, die beispielsweise Wissen, Fähigkeiten, Konzepte oder Missverständnisse repräsentieren [6]. Allerdings stellt in der Praxis die Definition der bedingten Wahrscheinlichkeiten die Designer der Systeme vor die größte Herausforderung. Die bedingten Wahrscheinlichkeiten können aus empirischen Daten abgeleitet, von einer Domain Expert\*in festgelegt, oder basierend auf einer allgemeinen Theorie über Beziehungen zwischen diesen Arten von Variablen definiert werden. Da diese Ansätze sehr aufwändig und fehleranfällig sind, basieren die bedingten Wahrscheinlichkeiten der meisten Systeme auf vereinfachenden Annahmen [6] [7].

#### 3.5.1 Noisy-AND und Leaky-OR Gatter

VanLehn et al. 1998 [19] führt mit dem **Noisy-AND** Gatter so eine vereinfachende Annahme ein. Dabei müssen für eine positive Prognose eines Knotens alle mit dem Noisy-AND Gatter verknüpften Elternknoten erfüllt sein. Die Prognose liegt in diesem Fall bei 1 - *slip*. Wenn auch nur ein Elternknoten nicht erfüllt ist, liegt die bedingte Wahrscheinlichkeit bei *guess* [19] [6].

Bei dem **Leaky-OR Gatter** hingegen genügt für eine positive Prognose eines Knotens, dessen Elternknoten mit einem LOR Gatter verbunden sind, wenn ein Elternknoten erfüllt ist. In diesem Fall ist die bedingte Wahrscheinlichkeit der Variable des Knotens 1 - *slip*. Wenn kein Elternknoten erfüllt ist, liegt die Prognose hingegen nur bei *guess* [5] [6].

Die Wahrscheinlichkeiten von *slip* und *guess* werden entweder global, oder wie bei VanLehn et. al 1998 [19] abhängig von der Anzahl der jeweiligen Antwortmöglichkeiten definiert [6]. Die Noisy-AND und Leaky-OR Gatter bilden die Grundlage für die NIDA und NIDO Modelle, die in Abschnitt 3.4 vorgestellt wurden.

### 3.5.2 Beispiel: BN mit knowledge tracing

Nach der Definition der bedingten Abhängigkeiten mittels Leaky-OR und Noisy-AND Annahmen und anschließender Initialisierung liegt für jeden Knoten eine Wahrscheinlichkeitsverteilung vor. *Abbildung 1* repräsentiert ein Bayessches Netz, in dem die Wahrscheinlichkeit *guess* eines Knoten mit weißen Knoten und  $1 - \text{slip}$  mit grauen Knoten repräsentiert wird. Die Knoten der Konzepte sind unsichtbar. Die Eingaben der Student\*innen haben direkt nur Einfluss auf die sichtbaren Knoten der Aufgaben  $A_1, \dots, A_4$ . Bei den Konzepten repräsentiert die Knotenfarbe die Wahrscheinlichkeit, dass die Student\*in das jeweilige Konzept anwenden kann. Die Farben der Aufgabenknoten hingegen repräsentieren die Wahrscheinlichkeit mit der die Student\*in die Aufgabe lösen kann. Die Eingabe einer korrekten Lösung für  $A_3$  führt unter Anwendung der Leaky-OR Gatter Annahme zur Aktualisierung der Wahrscheinlichkeit  $K_3$  auf  $1 - \text{slip}$ . Dieser Schritt wird auch **upward propagation** genannt [7]. Da die Wahrscheinlichkeitsverteilung des Konzepts  $K_2$  noch auf dem Wert *guess* steht, findet aufgrund der Noisy-AND Gatter Annahme keine upward propagation zum Konzept  $K_1$  statt. Allerdings wird aufgrund des neuen Wertes von  $K_3$  die Wahrscheinlichkeit der Student\*in die Aufgaben  $A_2$  und  $A_4$  zu lösen neu bewertet und anhand der Leaky-OR Gatter Annahme auf  $1 - \text{slip}$  gesetzt. Dieser Schritt wird auch **downward propagation** bezeichnet [7].




Abbildung 1: Bayessches Netz aus sichtbaren Aufgaben und unsichtbaren Konzepten (*Eigene Darstellung, Idee nach [6]*)

## 4 Fazit und Ausblick

Die Entwicklung und Verbreitung von ITS wächst seit Jahrzehnten. Immer mehr ITS werden als fester Bestandteil der Bildung angesehen und die erfolgreichsten ITS werden von hunderttausenden Benutzer\*innen pro Jahr verwendet [6]. Dieser Erfolg beruht nicht zuletzt auf dem Einsatz von psychologisch und mathematisch fundierten Lösungsansätzen für Unsicherheitsmanagement in Studierenden Modellen. In dieser Ausarbeitung wurden einige der wichtigsten Lösungsansätze wie knowledge/model tracing, IRT und Bayessche Netze vorgestellt. Aufgrund des Umfang der Ausarbeitung war es nicht möglich Unsicherheitsmanagement für bedingungs-basierte Tutoren [11] zu betrachten. Die meta-analytische Studie von Steenbergen-Hu et. al 2014 [16] hat ergeben, dass ITS effizienter sind als eigenständiges Lernen, CAI - Systeme und Klassenunterricht. Tatsächlich erreichen sie fast die Effizienz eines individuellen Privatunterrichts, welcher als Vorbild für ITS gilt. Während bislang fast alle ITS für mathematisch-physikalische Disziplinen entwickelt wurden bei denen die Grenzen zwischen Richtig und Falsch leicht zu ziehen sind, werden ITS für Sprach- und Geisteswissenschaften bislang kaum erforscht. Die Entwicklung von ITS für schwer abgrenzbare Domänen würde daher ein ganz neues Feld von Einsatzgebieten für ITS in der Bildung erschließen [16]. Die Forschung und insbesondere der Einsatz von ITS im öffentlichen Bildungssystem innerhalb der EU wird aufgrund der umfangreichen Sammlung personenbezogener Daten absehbar zu Konflikten mit der Europäische Datenschutzgrundverordnung [18] führen. Eine Diskussion der moralischen und rechtlichen Konflikte um personenbezogene Daten im Bildungssystem kann im Rahmen dieser Ausarbeitung nicht geleistet werden.

## Literatur

- [1] John R. Anderson, Albert T. Corbett, Kenneth R. Koedinger, and Ray Pelletier. Cognitive tutors: Lessons learned. *The Journal of the Learning Sciences*, 4(2):167–207, 1995.
- [2] Kathy Anderson. Computer-assisted instruction. *Journal of Medical Systems*, 10(2):163–171, Apr 1986.
- [3] Ryan SJ d Baker, Albert T Corbett, and Vincent Aleven. More accurate student modeling through contextual estimation of slip and guess probabilities in bayesian knowledge tracing. In *International Conference on Intelligent Tutoring Systems*, pages 406–415. Springer, 2008.
- [4] Jaime R Carbonell. Ai in cai: An artificial-intelligence approach to computer-assisted instruction. *IEEE transactions on man-machine systems*, 11(4):190–202, 1970.
- [5] Cristina Conati, Abigail Gertner, and Kurt Vanlehn. Using bayesian networks to manage uncertainty in student modeling. *User modeling and user-adapted interaction*, 12(4):371–417, 2002.
- [6] Michel C Desmarais and Ryan S Baker. A review of recent advances in learner and skill modeling in intelligent learning environments. *User Modeling and User-Adapted Interaction*, 22(1-2):9–38, 2012.
- [7] Anthony Jameson. Numerical uncertainty management in user and student modeling: An overview of systems and issues. *User Modeling and User-Adapted Interaction*, 5, 1996.
- [8] Kenneth R Koedinger, John R Anderson, William H Hadley, and Mary A Mark. Intelligent tutoring goes to school in the big city. 1997.
- [9] Eva Millán and José Luis Pérez-de-la Cruz. A bayesian diagnostic algorithm for student modeling and its evaluation. *User Modeling and User-Adapted Interaction*, 12(2):281–330, Jun 2002.
- [10] Eva Millán, Tomasz Loboda, and Jose Luis Pérez de-la Cruz. Bayesian networks for student model engineering. *Computers and Education*, 55(4):1663 – 1683, 2010.
- [11] Antonija Mitrovic. Fifteen years of constraint-based tutors: What we have achieved and where we are going. *User Modeling and User-Adapted Interaction*, 22(1-2):39–72, April 2012.
- [12] Stellan Ohlsson. Constraint-based modeling: From cognitive theory to computer tutoring – and back again. *International Journal of Artificial Intelligence in Education*, 26(1):457–473, Mar 2016.
- [13] John A Self. Formal approaches to student modelling. In *Student modelling: The key to individualized knowledge-based instruction*, pages 295–352. Springer, 1994.
- [14] Glenn Shafer and Amos Tversky. Languages and designs for probability judgment. *Cognitive Science*, 9(3):309 – 339, 1985.
- [15] Valerie J Shute and Joseph Psotka. Intelligent tutoring systems: Past, present, and future. Technical report, ARMSTRONG LAB BROOKS AFB TX HUMAN RESOURCES DIRECTORATE, 1994.
- [16] Saiying Steenbergen-Hu and Harris Cooper. A meta-analysis of the effectiveness of intelligent tutoring systems on college students’ academic learning. *Journal of Educational Psychology*, 106(2):331, 2014.
- [17] Kikumi K. Tatsuoka. Rule space: An approach for dealing with misconceptions based on item response theory. *Journal of Educational Measurement*, 20(4):345–354, 1983.
- [18] Europäisches Parlament und Rat. Verordnung (EU) 2016/679 des Europäischen Parlaments und des Rates v. 27.04.2016 zum Schutz natürlicher Personen bei der Verarbeitung personenbezogener Daten, zum freien Datenverkehr und zur Aufhebung der Richtlinie 95/46/EG (Datenschutz-Grundverordnung).

- [19] Kurt VanLehn, Zhendong Niu, Stephanie Siler, and Abigail S Gertner. Student modeling from conventional test data: A bayesian approach without priors. In *International Conference on Intelligent Tutoring Systems*, pages 434–443. Springer, 1998.