

# Learning Companions

Virtuelle, autonome Mitlernende  
in Intelligent Tutoring Systems

Präsentation der folgenden Papers:

Encouraging Student Reflection and Articulation using a Learning Companion  
von Goodman et al.

The Competence of Learning Companion Agents  
von Hietala et al.

## Einleitung

In modernen Bildungs-Applikationen findet sich eine Vielzahl von verschiedenen intelligenten Agenten. Die meisten lassen sich folgenden Kategorien zuordnen:

- "Tool"-ähnliche Agenten: Diese unterstützen den Benutzer beim selbständigen Arbeiten. Es handelt sich mehr um intelligent agierende Werkzeuge als um virtuelle Persönlichkeiten. Ein Beispiel hierfür sind Suchmaschinen, die digitale Archive durchforsten.
- Virtuelle Lehrende: auch "Tutoren" oder "Coaches" genannt. Es handelt sich hierbei um simulierte Lehrpersonen, die in ein *Intelligent Tutoring System* (ITS) eingebaut sind. Sie können dem menschlichen Benutzer Aufgaben stellen, aber auch dem Benutzer Hilfe leisten, indem sie von ihm gestellte Fragen beantworten. Für virtuelle Lehrende gilt das *Intelligent Tutoring Paradigm*: Der Tutor muss alles wissen und darf nur fehlerfreie Antworten liefern. Hingegen wird von einem Tutor nicht erwartet, dass er ständig erreichbar ist; er muss also nicht auf jede Anfrage seitens des Benutzers reagieren.
- Virtuelle Mitlernende: Hier werden drei verschiedene Arten unterschieden:
  - *Co-Learners*: Der Agent und der Benutzer beginnen mit einem vergleichbaren Wissensstand. Gemeinsam erarbeiten sie Lösungen zu gegebenen Problemstellungen. Der Co-Learner ersetzt den Tutor, wengleich er eine andere Aufgabe und Funktionalität hat.
  - *Learning by teaching*: Der Agent hat anfangs einen geringeren Wissensstand als der Benutzer; der Benutzer übernimmt die Rolle des Lehrenden. Durch das Unterrichten lernt er selbst dazu. Auch in Systemen nach diesem Prinzip kommt kein Tutor vor.
  - *Learning Companions*: Im Gegensatz zu den beiden vorhergehenden Varianten sind Learning Companions (LC) als Ergänzung zu Tutoren in ITS konzipiert. Agent und Benutzer erarbeiten gemeinsam Aufgaben, die ihnen der Tutor stellt, und diskutieren miteinander über verschiedene Lösungsansätze. Im Gegensatz zu einem Tutor ist ein LC jedoch nicht allwissend und kann daher nicht immer zuverlässige Antworten liefern.

Die Learning Companions sollen das Thema dieses Textes sein.

## **Exkurs: Arten von virtuellen Lernumgebungen**

In den hier besprochenen Papers werden drei Arten von virtuellen Lernumgebungen unterschieden:

- **Intelligent Tutoring System:** abgekürzt ITS. Ein ITS ist eine virtuelle Lernumgebung mit zumindest einem virtuellen Lehrenden. Manche moderne ITS haben als zusätzliche Komponente einen LC. Ein ITS ist in der Regel für die Verwendung durch Einzelpersonen ausgelegt.
- **Computer-Supported Collaborative Learning:** abgekürzt CSCL. CSCL-Lernumgebungen sind für zwei oder mehrere Benutzer ausgelegt. In solchen Systemen werden keine intelligenten Agenten eingesetzt. Statt dessen sollen die Benutzer von- und miteinander lernen. Der Computer unterstützt sie im Prinzip nur bei der Kommunikation.
- **Intelligent Collaborative Learning System:** abgekürzt ICLS. Hierbei handelt es sich um ein ITS mit einem LC, welches für mehrere Benutzer konzipiert ist. Somit verknüpft ein ICLS Elemente sowohl eines ITS als auch von CSCL.

## **Sinn und Zweck von Learning Companions**

LC sind für die Verwendung in ITS (bzw. ICLS) ausgelegt. Eine große Stärke dieser Systeme ist die individuelle Betreuung des Benutzers. Durch den LC erhält das System aber auch die Vorteile des Lernens in Kleingruppen (s.u.), wie sie etwa in einem CSCL gegeben sind. Der große Vorteil gegenüber menschlichen Lernpartnern und damit auch gegenüber CSCL besteht aber darin, dass der LC ständig verfügbar sind.

Der große Vorteil des Lernens in Kleingruppen mit gleichrangigen Partnern (*peers*) besteht darin, dass die Lernenden in einen sinnvollen Dialog eingebunden werden. Dies fördert den Lernfortschritt. Insbesondere zwei Stichworte seien in diesem Zusammenhang genannt:

- Artikulation und
- Reflexion.

Sowohl Artikulation als auch Reflexion helfen, das Wissen besser zu strukturieren, und nützen damit dem Lernprozess.

Artikulation, also Äußerung der Gedanken, verstärkt die Merkfähigkeit (*retention*) und hilft, Zusammenhänge deutlicher zu erkennen. Dadurch, dass der sich Artikulierende von seinem Gegenüber unverzüglich "Feedback" erhält, wird er für besonders schwierige Punkte sensibilisiert. Der Lernende wird zudem gezwungen, sein Wissen vor Gleichen zu verteidigen. Dies hat zur Folge, dass er seinen eigenen Kenntnisstand bewerten und sich entscheiden muss, auf welcher Schwierigkeitsstufe er mit dem Lernen fortsetzt.

Reflexion, d. h. Nachdenken, bringt Lernende dazu, ihre eigenen Strategien zu analysieren, die Unterschiede zwischen diesen und den Vorgehensweisen anderer Personen, sowohl von Neulingen als auch Experten, zu erkennen, durch Abstraktion allgemeine Lösungswege zu finden und in Zukunft bessere Entscheidungen zu treffen.

## Anforderungen an Learning Companions

Die Fähigkeit zur Zusammenarbeit (*collaboration*) gilt als wichtigste Eigenschaft sinnvollen und effektiven Arbeitens. Zudem ist bei einem LC die Kommunikationsfähigkeit von großer Bedeutung. Darunter versteht man die Bereitschaft zu Kooperation und Eigeninitiative - der Agent soll nicht nur auf die Eingaben des Benutzers reagieren, sondern auch von selbst agieren können - sowie autonomes Handeln.

## Historische Entwicklung und Trennung Tutor - LC

1992 wurde mit Sherlock II erstmalig ein Tutor entwickelt, der nicht nur die Fragen des Benutzers beantwortet, sondern auch den vom Benutzer eingeschlagenen Lösungsweg mit seinem eigenen vergleicht. Diese Vorgehensweise wird auch *reflective follow-up* genannt.

Dieser Agent wurde später erweitert, so dass er bald gemeinsam mit dem Benutzer an Aufgaben zusammenarbeiten konnte; der Benutzer konnte ihm zudem selbst Aufgaben stellen und seine Lösungsansätze kritisieren. Der Tutor stellte dem Benutzer Fragen, welche ihn beim Lösen der Aufgaben unterstützen sollten; dies bezeichnet man als *Learning Conversation*.

Sherlock II erfüllte also schon wesentliche Funktionen eines LC, obwohl es sich an sich um einen Tutor handelte. Auf Grund der unterschiedlichen Erwartungen an Lehrende und Mitlernende, was einerseits die Qualität der Antworten auf gestellte Fragen, andererseits die Erreichbarkeit angeht, erschien es jedoch sinnvoll, diese beiden Funktionen zu trennen; dies war die Geburtsstunde der LC. Wichtig ist auch der psychologische Aspekt: Die Hemmschwelle, sich einem Gleichrangigen (wie dem LC) anzuvertrauen, ist geringer, als wenn man sein Anliegen der höchsten Autorität (dem Tutor) vortragen müsste.

Die Unterscheidung zwischen Tutor und LC hat zudem einen weiteren Vorteil: Die Interaktion des Benutzers mit dem LC führt zur Gewinnung von Informationen für das Benutzer-Modell des ITS; auf dieses kann nun auch der Tutor zugreifen, was wiederum eine bessere Betreuung des Benutzers und eine bessere Auswahl der Aufgaben ermöglicht.

**Table 1.** Comparison of student/tutor dialogue vs. student/peer dialogue

Student/Tutor Dialogue		Student/Peer Dialogue	
Student:	What do you think I should do next?	Student:	What do you think I should do next?
Tutor:	Link an explanation to some evidence.	LuCy:	Link an explanation to some evidence. What do you think?
		Student:	I do not think that is a good idea.
		LuCy:	What would you suggest?
		Student:	Choose the best explanation.
		LuCy:	Which one do you think is best?
		Student:	A failure in the satellite's ground station forced the orbit change.
		LuCy:	Why would you choose that as the best explanation?
		Student:	I have found conclusive evidence supporting this explanation.
		LuCy:	I don't think that's a good reason. Let's ask the instructor.

Obige Tabelle (aus Goodman et al.) verdeutlicht eindrucksvoll den Unterschied zwischen einem Student-Tutor- und einem Student-LC-Gespräch. Beide Male stellt der Student dieselbe Frage und erhält dieselbe Antwort. Während danach aber das Student-Tutor-Gespräch bereits beendet ist, fragt der LC den Studenten um seine Meinung. Der Student erklärt, dass er den Vorschlag des LC "für keine gute Idee" hält. Daraufhin lässt der LC den Studenten seinerseits eine Lösung vorschlagen und ihn begründen, warum er für diese Lösung ist. Schließlich teilt der LC dem Benutzer seine Meinung über diese Begründung mit und schlägt vor, den Tutor zu konsultieren.

Während die Antwort des Tutors absolute Autorität besitzt, also im Prinzip einen Befehl darstellt, stellen die Angaben des LC eine Meinungsäußerung dar. Damit gibt der LC im Gegensatz zum Tutor dem Benutzer die Möglichkeit zu widersprechen. Indem der LC den Benutzer in einem Dialog seine Ansichten artikulieren und begründen lässt, kann einerseits der Benutzer unmittelbar lernen, indem er etwa erkennt, dass er falsche Schlussfolgerungen angestellt hat. Andererseits können wertvolle Informationen über die Denkstruktur des Benutzers gewonnen werden. Diese können in einem Benutzermodell auch dem Tutor zugänglich gemacht werden und sich auf sein Verhalten dem Benutzer gegenüber auswirken, z.B. in Bezug auf die Auswahl der Aufgaben.

Aus dem kurzen Student-Tutor-Dialog lernen hingegen möglicherweise weder der Benutzer noch das ITS allzu viel. Falls der Benutzer nicht versteht, warum die vom Tutor vorgeschlagene Vorgehensweise richtig ist, kann er entweder die Anweisung des Tutors blindlings befolgen oder ignorieren. Beides ist nicht optimal.

## Die Papers

*Goodman et al. 1998:*

### ***Encouraging Student Reflection and Articulation using a Learning Companion***

Ziel dieser Arbeit war die Entwicklung eines LC (genannt "LuCy") für ein existierendes ITS ("PROPA" von MITRE Corp.), der zu Artikulation und Reflexion anregt.

PROPA ist ein ITS, das der Schulung von Satellitentechnikern dient. Ziel ist es, *explanatory analysis* zu unterrichten. Unter *explanatory analysis* versteht man in diesem Kontext die Fähigkeit, technische Probleme zu analysieren und ihre Ursachen verständlich zu erklären. Der Benutzer soll lernen, Hypothesen zu erstellen, nach Hinweisen zu suchen, die diese unterstützen oder widerlegen, und deren Bedeutung und Verlässlichkeit richtig einzuschätzen.

Die Benutzerinteraktion erfolgt in PROPA über die "*Argument-Palette*", welche die Verknüpfung von Fakten mit Hypothesen und die Gewichtung der Argumente ermöglicht.

Nach Goodman werden beim gemeinsamen Erarbeiten von Hypothesen in der Gruppe von den einzelnen Mitarbeitern unterschiedliche Rollen übernommen. Goodman erwähnt folgende Rollen:

- Ausführer (*executive*): schlägt Lösungswege oder Handlungen vor
- Kritiker (*critic*): stellt Ideen, Pläne oder Absichten in Frage
- Lehrer (*instructor*): erklärt Konzepte
- Aufzeichner (*record keeper*): behält Stand der Lösung und Gespräche im Auge
- Schlichter (*conciliator*): löst interne Konflikte

Von diesen übernimmt LuCy in der derzeitigen Version die Rolle des Motivators und des Kritikers. Als Motivator versucht LuCy, dem Benutzer zu helfen, auf dem richtigen Weg zu bleiben und nicht aufzugeben. Seine Kritik formuliert LuCy als Meinung und gibt so dem Benutzer die Möglichkeit, zuzustimmen oder abzulehnen. Die Antwort des Benutzers könnte Hinweise für das Benutzermodell bergen und sich so auf die Effektivität des Tutors positiv auswirken.

Im Benutzermodell von PROPA werden vornehmlich die Kenntnisse einzelner Regeln für bestimmte Wissensbereiche bewertet. Es gibt folgende Bewertungsstufen:

- Noch nicht versucht (*untried*): Der Benutzer hat diese Regel bisher noch nicht angewandt, sei es, dass er nicht wusste, dass sie in einem bestimmten Fall anzuwenden ist, oder dass diese Regel womöglich in keinem der Fälle, mit dem er bisher zu tun hatte, anzuwenden war.
- In Übung (*practicing*): Der Benutzer hat diese Regel schon mindestens einmal angewandt, allerdings noch nicht so oft, dass man mit einiger Sicherheit vermuten könnte, er wisse, wann diese Regel anzuwenden ist.
- Erlernt (*learned*): Der Benutzer hat diese Regel schon öfter richtig angewandt. Es scheint, als ob er wisse, wann man diese Regel zu benutzen hat und wann man von ihrem Gebrauch Abstand nehmen soll.
- Blockiert (*blocked*): Diese Regel wurde vom Benutzer mehrere Male falsch gebraucht oder ignoriert. In diesem Fall sucht der Tutor vorerst Aufgaben aus, die den Gebrauch dieser Regel nicht erfordern, um dem Benutzer andere Regeln beizubringen; erst wenn der Benutzer eine bestimmte Zahl anderer Regeln erlernt hat, wird die Blockade wieder aufgehoben und nochmals versucht, dem Benutzer diese Regel beizubringen.

Der Punktestand für jedes Wissensgebiet wird durch Mittelung der Punkte für die relevanten Regeln ermittelt. Sobald alle Regeln erlernt wurden, gilt das Gebiet als abgeschlossen (*completed*). Das implizite Ziel von PROPA ist es, alle Gebiete zu einem Abschluss zu bringen.

Die Werte für die Kenntnisse der einzelnen Regeln werden im Zuge der Übungen ermittelt. Zudem gibt die visuelle Repräsentation der Argumentation dem ITS Aufschluss über die Denkstruktur des Benutzers, ebenso wie die Interaktion zwischen dem Benutzer und LuCy.

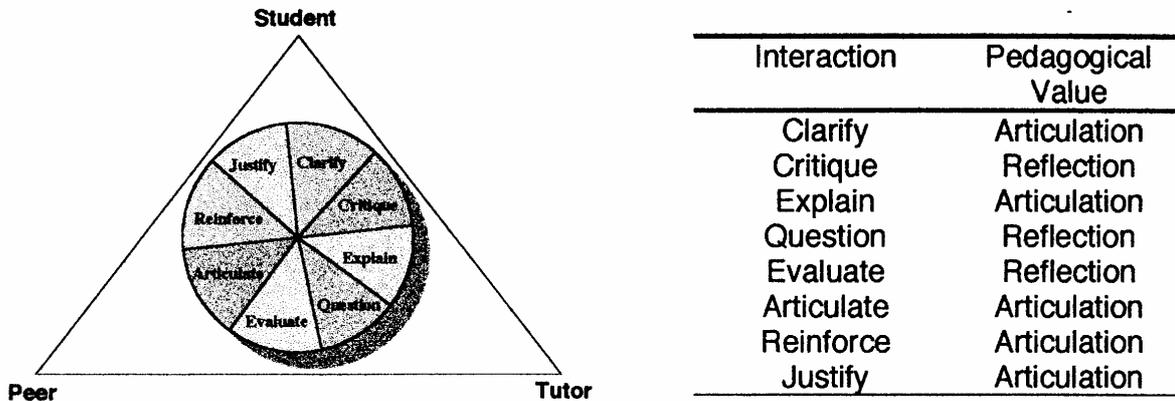
Das Benutzermodell ermöglicht dem Tutor, maßgeschneiderte Antworten auf die Fragen des Benutzers zu geben, abhängig von dessen Wissensstand, der Zahl bereits gegebener relevanter Tipps und der Bedeutung des aktuellen Schritts für die Lösung des Problems.

Da auch LuCy auf das Benutzermodell zugreifen kann, wirkt es sich zudem auch auf das Verhalten des LC gegenüber dem Benutzer aus. Je erfahrener der Benutzer bereits mit der Anwendung einer Regel ist, desto häufiger gibt LuCy

falsche Auskünfte bezüglich dieser Regel. Dies soll der Erziehung zu Selbständigkeit dienen und den Benutzer zwingen, sein Wissen zu verteidigen.

Defaultwerte für die Wahrscheinlichkeit, dass LuCy eine falsche Auskunft gibt:

- bei "untried": 0,2
- bei "practicing": 0,5
- bei "learned": 0,8

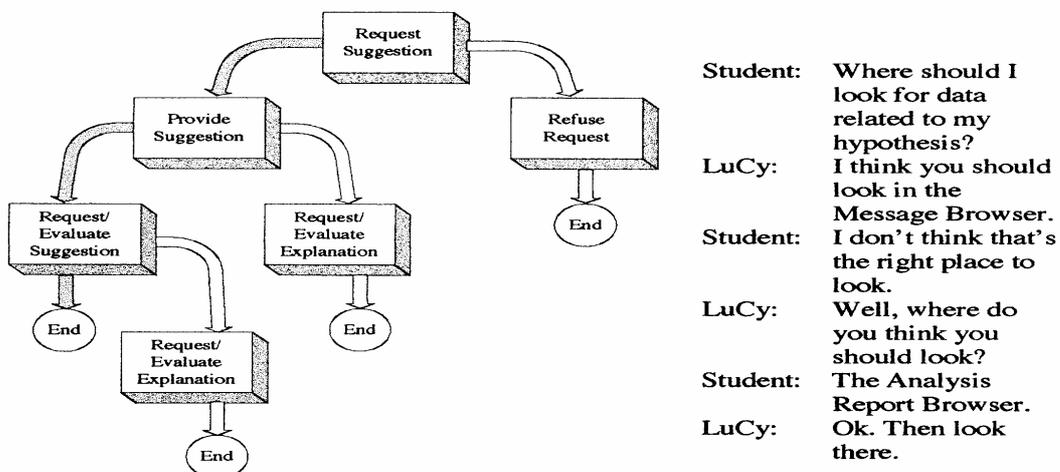


**Figure 4.** The Learning Triangle showing types of dialogue interactions

Die Interaktion zwischen LuCy und dem Tutor erfolgt ausschließlich über das Benutzermodell. Der Benutzer kommuniziert mit LuCy (ähnlich wie mit dem Tutor) über menügeführte Dialoge. Antworten auf Fragen LuCys kann er aus einer Liste auswählen. Zudem kann er dem Agenten selbst 32 verschiedene Fragen stellen, welche häufig zu längeren Dialogen führen. Diese Fragen lassen sich grob zwei Kategorien zuordnen:

- Bitten um Vorschläge ("Was soll ich als Nächstes tun?") und
- Bitten um Meinungen ("War meine letzte Handlung richtig?").

Der Benutzer kann seine eigene Meinung auch selbst äußern. Da die Gespräche in Kontext der Argument-Palette stehen, besteht trotz des Zwangs, Fragen und Antworten aus einer begrenzten Liste auszuwählen, keine wesentliche Einschränkung der Ausdrucksfähigkeit.



**Figure 8.** Dialogue scheme for a typical student/learning companion dialogue with actual dialogue

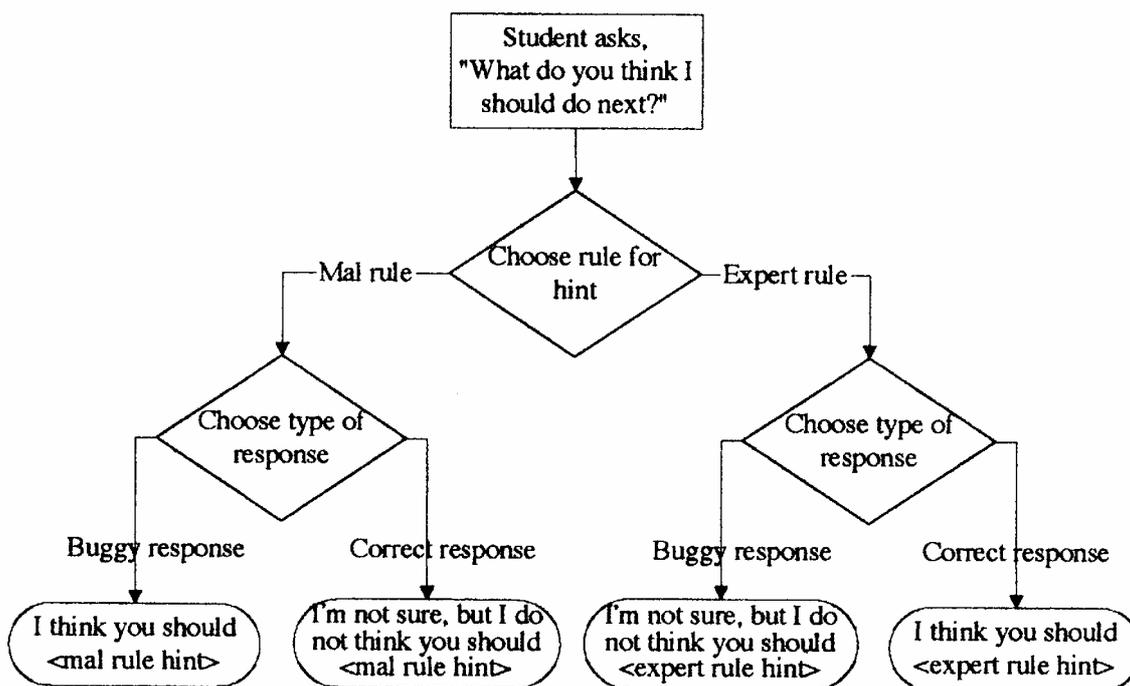
Im Gegensatz zum Tutor, der wie ein Lehrer im echten Leben nicht ständig erreichbar ist, sondern nur in 80% der Fälle auf Anfragen des Benutzers reagiert (dies wird durch einen Zufallsalgorithmus realisiert, der Grund besteht in der Erziehung zur Selbständigkeit), ist LuCy immer ansprechbar, gibt aber manchmal falsche Antworten (s.o.).

Zu den von LuCy angebotenen Hilfestellungen gehören:

- Verknüpfen von Hinweisen mit Erklärungen,
- Aufzeichnen von Hinweisen (*record evidence*),
- Suchen nach Daten und
- Auswählen neuer Hypothesen.

LuCy hat Zugriff auf das Wissen des Tutors (*expert rules*) und auf eine Datenbank gängiger Irrtümer (*mal rules*). Bei den *expert rules* handelt es sich um die im jeweiligen Kontext anzuwendenden, richtigen Regeln. Unter *mal rules* versteht man hingegen in diesem Kontext falsche, nicht anzuwendende Regeln, die auf gängigen falschen Vorstellungen (*misconceptions*) beruhen.

Bittet der Benutzer LuCy um Hilfe, so entscheidet LuCy zuerst, ob sie dem Benutzer eine *expert rule* oder eine *mal rule* mitteilen soll und danach, ob die Auskunft korrekt oder falsch sein soll. Auf Grund dieser Beschlüsse wählt LuCy dann die Regel aus und formuliert den Aussagesatz.



**Figure 9.** LuCy's decision process

Eine Besonderheit von LuCy gegenüber anderen LC besteht darin, dass LuCy auf die Wissensbasis des Tutors, also auf Expertenwissen Zugriff hat. Damit kann LuCy Fehler des Benutzers erkennen. Viele andere LC lernen hingegen nur mit dem Benutzer mit, wissen also nicht mehr als dieser.

Zudem besteht der hauptsächliche Zweck von LuCy darin, den Benutzer zu ermutigen, Gedanken über seine Handlungen und Entscheidungen zu äußern und

über sie nachzudenken (Artikulation und Reflexion). Andere LC arbeiten hingegen nur mit den Benutzern beim Lösen der Probleme zusammen oder konkurrieren mit ihnen, erfüllen aber den Zweck von LuCy nicht.

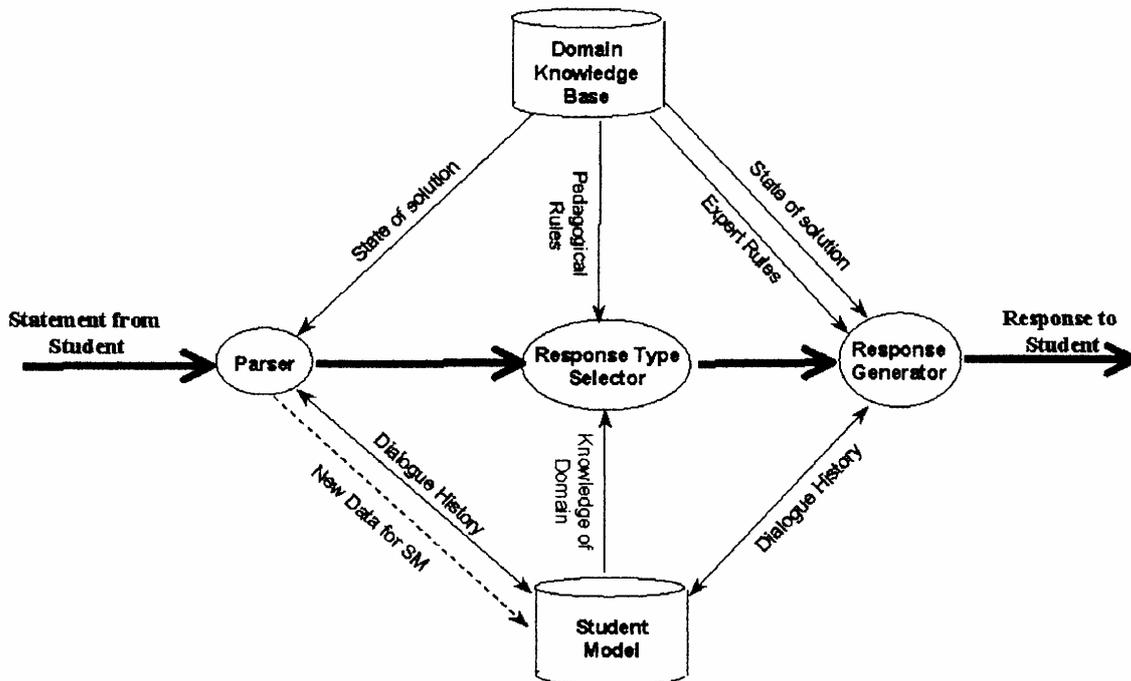


Figure 10. LuCy's architecture

Die nächsten Versionen von LuCy sollen in ein ICLS, basierend auf der *Habanero*-Plattform, eingebettet werden und ein Lernen in der Gruppe zusammen mit dem LC ermöglichen. Dabei soll LuCy die in der Gruppe noch unbesetzten Rollen (z.B. die des Mittlers oder des Mentors) dynamisch ausfüllen, natürliche Sprache verarbeiten können, die Fähigkeit haben, die eigenen Kenntnisse zu demonstrieren, und nebenbei automatisch ein Gruppenmodell anlegen, welches darüber Auskunft gibt, welcher Benutzer welche Rolle in der Gruppe wie gut ausübt und wie hoch die Gesamtleistung der Gruppe ist.

*Hietala et al. 1997:*

### ***The Competence of Learning Companion Agents***

Diese Studie untersucht die Frage der "Kompetenz" von LCs, d.h. ihre Fähigkeiten in Bezug auf Wissen, Problem lösen und Erklären. Ein großes Problem besteht darin, die Fähigkeiten der Agenten an die Bedürfnisse des Benutzers anzupassen, um einen optimalen Lernfortschritt zu erzielen. Bisherige Erfahrungen haben gezeigt, dass einerseits "angstliche" Agenten, die den Benutzer ständig unterbrechen und Feedback einfordern, auf die Dauer nerven. Andererseits rufen Agenten, die mit dem Lernfortschritt des Benutzers nicht Schritt halten und zu viele falsche Antworten geben, häufig Ärger hervor und werden vom Benutzer als überflüssig erachtet.

In dieser Studie kamen zwei Arten von LC zum Einsatz, "starke" und "schwache". Starke Agenten haben gute Kenntnisse und geben stets fehlerfreie Antworten, wenngleich diese nicht immer optimal sind. Schwache hingegen geben anfangs meistens falsche Antworten, weil sie zunächst alle Antworten per Zufallsgenerator auswählen; mit der Zeit "lernen" sie aber, so dass sie immer

öfter richtige Antworten geben. Technisch wird dies realisiert, indem die Zahl der nicht zufällig ausgewählten korrekten Antworten mit der Zeit zunimmt.

(In diesem Zusammenhang fällt auf, dass der in Goodmans Paper vorgestellte Agent LuCy in keine dieser beiden Kategorien fällt. Im Gegensatz zu den schwachen Agenten nimmt die Wahrscheinlichkeit, dass LuCy eine falsche Auskunft gibt, sogar mit dem Wissensstand des Benutzers zu. Der Grund hierfür ist, dass der Benutzer Selbstsicherheit gewinnen und lernen soll, sein Wissen zu verteidigen. Allerdings muss dazu gesagt werden, dass dies nur bei den Default-Einstellungen von LuCy gilt. Goodman und seine Mitarbeiter schlagen drei weitere mögliche Strategien vor: dem Agenten ein konstantes Kompetenzniveau zu geben, seine Kompetenz an die des Benutzers fix zu binden oder Agent und Benutzer mit unterschiedlichen Ausgangskompetenzen starten zu lassen, aber die Kompetenzentwicklung des Agenten parallel zum Benutzer zu gestalten.)

In dem in der Studie verwendeten ITS *EduAgents*, einer auf MS Windows basierenden Lernumgebung für elementare Algebra, die mit *LPA-WinProlog* erstellt wurde, unterscheiden sich starke und schwache Agenten zudem noch durch ihre Sprechweise (*manner of speaking*). Während die starken Agenten selbstsicher und damit bisweilen sogar herrisch klingen, wirken die schwachen etwas unsicher und zögerlich ("I guess ..., but I am not sure").

Insgesamt gestattet *EduAgents* die Wahl zwischen vier verschiedenen LC mit unterschiedlichen Namen, Erscheinungsbildern, Fähigkeiten und Ausdrucksweisen; kurz, es wurde versucht, den Agenten verschiedene Persönlichkeiten zu geben. Dabei sind je zwei Agenten weiblich bzw. männlich sowie stark bzw. schwach. Alle Agenten greifen auf dieselbe Wissensbasis zu, sie unterscheiden sich nur darin, wie sie die Antworten auswählen.

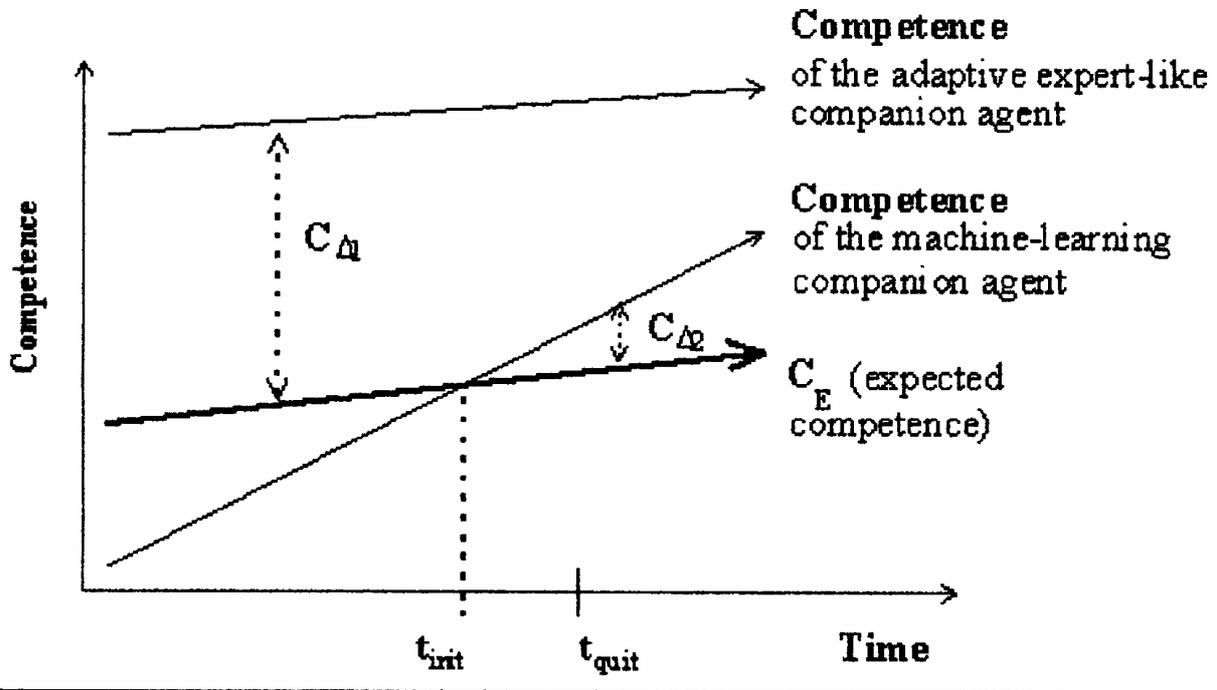
Die Auswahl des LC erfolgt über eine Palette, in welcher die zu den einzelnen Agenten gehörenden Icons zufällig angeordnet sind. Diese zufällige Anordnung sollte bewirken, dass die Benutzer, auch wenn sie stur immer wieder auf dieselbe Stelle klickten, mit verschiedenen Agenten in Kontakt kämen, um mit allen LC Erfahrungen sammeln und sie so miteinander vergleichen zu können. *EduAgents* erlaubt es, während einer Sitzung jederzeit zwischen den Agenten zu wechseln.

*EduAgents* verfügt über zwei verschiedene Kommunikationsschnittstellen zwischen dem Benutzer und dem LC. In der einfacheren, dem *Basic Working Interface*, kann der Benutzer den Agenten bitten, eine durchzuführende Operation oder ein Resultat vorzuschlagen. Anschließend kann er von ihm eine Erklärung einfordern, warum die angegebene Operation zielführend oder das Resultat korrekt sei. Die andere Schnittstelle, das *Collaboration Tool*, enthält eine mächtigere Dialogkomponente. Diese gestattet es, aus vordefinierten Satzgliedern Sätze zu bilden.

Die Studie wurde durchgeführt, um Hinweise auf die Antworten der folgenden vier Fragen bezüglich der Kompetenz von Agenten zu bekommen:

1. Wie lange darf die "Initiationsphase" dauern, bis der Agent die vom Benutzer erwartete Kompetenz erreicht hat, also  $C = C_E$ ?
2. Wie weit darf der Agent die erwartete Kompetenz überschreiten, ohne den Benutzer zu frustrieren; d.h. wie groß darf  $C_{\Delta 2}$  sein?

3. Wie groß darf der Unterschied zwischen den Kompetenzen des "Experten" (gemeint ist der starke Agent) starken und des Benutzers sein, um eine positive Beziehung Mensch-Maschine aufrecht zu erhalten; d.h. wie groß darf  $C_{\Delta 1}$  sein?
4. Welche Faktoren beeinflussen die Kompetenzerwartung?



**Figure 1. Learner's expectation of the companion's competence**

Die Studie wurde an 14 Jugendlichen im Alter von 13 Jahren durchgeführt. Diese Jugendliche hatten sich ohne Ausnahme freiwillig zur Teilnahme an der Studie gemeldet. Sie alle hatten nur geringfügige Vorkenntnisse aus dem Bereich der Algebra; dieser Stoff würde erst im Laufe des aktuellen Schuljahrs durchgenommen werden. Zur Motivation wurde eine Bildungs-CD-ROM als Preis versprochen.

Abgesehen von der geringen Zahl der Teilnehmer kann diese Studie insofern nicht repräsentativ sein, als 12 Probanden männlich, aber nur 2 weiblichen Geschlechts waren. Hingegen entspricht der durchschnittliche Intelligenzquotient mit 101,4 ungefähr dem Bevölkerungsschnitt.

Zunächst erfolgten zwei psychologische Tests. Auf Grund der Ergebnisse wurden die Probanden in je zwei Gruppen eingeteilt: einerseits auf Grund der Haltung gegenüber der Außenwelt in

- Extravertierte (E) und
  - Introvertierte (I),
- andererseits auf Grund der Intelligenz in
- W+ (die sieben Intelligenteren) und
  - W- (die sieben weniger Intelligenten).

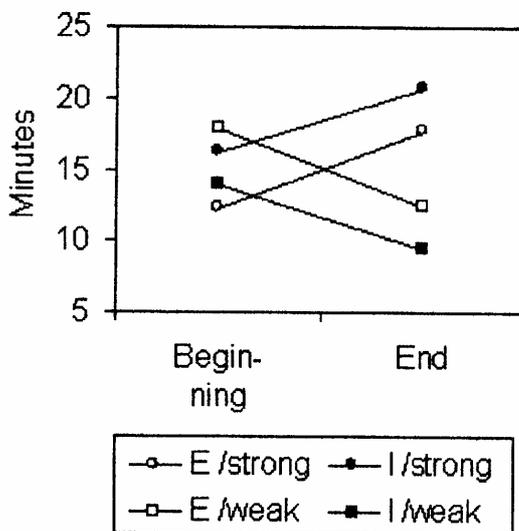
Danach wurden über einen längeren Zeitraum sechs EduAgents-Sitzungen zu je 30 Minuten durchgeführt. Nach jeder Sitzung fanden Gespräche mit den Probanden statt. Außerdem wurden vor der ersten sowie nach der fünften und

nach der sechsten Sitzung Algebra-Tests durchgeführt, um den Lernfortschritt messen zu können.

Die Ergebnisse geben zwar leider keine zufrieden stellende Antworten auf die vier Ausgangsfragen, aber vielleicht zumindest Hinweise für Folgestudien.

Was die erste Frage betrifft, stellte es sich heraus, dass allgemein anfangs eher die schwachen, später mit zunehmendem Schwierigkeitsgrad der Aufgaben eher die starken Agenten bevorzugt wurden. Vor allem Introvertierte (I) und Intelligenterer (W+) zogen die starken Agenten vor; die Introvertierten verbrachten mit diesen in den letzten beiden Sitzungen sogar 66% der Zeit. Extravertierte (E) und weniger Intelligente (W-) baten aber selbst zum Schluss oft auch schwache Agenten um Hilfe.

4a. Extravert and introvert subjects with strong and weak companion agents



4b. W+ and W- subjects with strong and weak companion agents

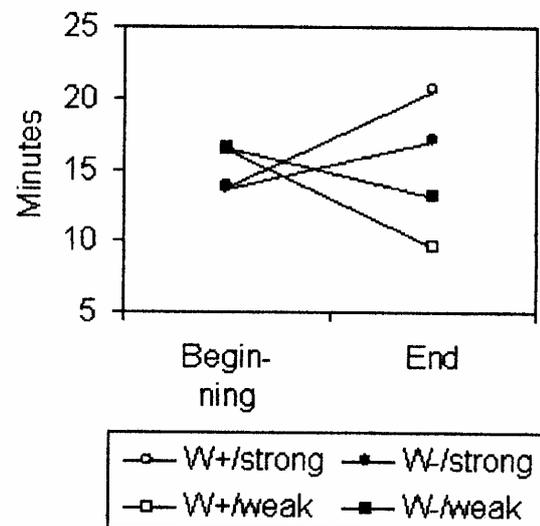


Figure 4. The average time subjects spent with the strong and weak companion agents at the beginning (sessions 1-3) and at the end (sessions 4-6)

Hietala und Mitarbeiter kamen zu dem Schluss, dass bei einfachen Problemstellungen die Mensch-Maschine-Kommunikation eher sozialer und vielseitiger Natur sein dürfte. Erst bei schwierigeren Problemen würden die Agenten tatsächlich um Lösungsvorschläge gebeten werden. Dabei ziehen die Gruppen E und W- schwächere, I und W+ hingegen stärkere LC vor.

In Bezug auf die zweite Frage fiel auf, dass sich nur die Angehörigen der Gruppe W+ im Collaboration Tool selbst an den Fragestellungen versuchten. Zudem stellten die Forscher fest, dass die Gruppen E und W- den Weg der Zusammenarbeit mit den schwächeren Agenten wählten, selbst wenn deren Kompetenz derjenigen der starken Agenten bereits fast entsprach.

Was die dritte Frage anbelangt, wurde lediglich festgestellt, dass sich bei schwierigen Aufgabenstellungen die Gruppen I und W+ für den Erfolg versprechenden Weg (nämlich die Zusammenarbeit mit den starken Agenten) entschieden. Von den Agenten erbaten sie Hinweise auf die nächsten Lösungsschritte.

Bezüglich der vierten Frage ergab die Untersuchung, dass die Persönlichkeit des Agenten, v.a. seine Sprache und seine Stimme, die Kompetenzerwartung beeinflusse. Die Autoren vermuten, dass sich die Angehörigen der Gruppen W- und E auf Grund der mangelnden Fähigkeiten und der zögerlichen Art zu sprechen der schwächeren Agenten bei diesen "wohler fühlten".

Interessanterweise wurden die LC häufig gewechselt: zum Schluss wurden in jeder Sitzung durchschnittlich 3,25 Agenten verwendet. Dabei wechselten die Introvertierten die Agenten öfter, verbrachten aber insgesamt deutlich mehr Zeit mit den starken. Alle LC wurden praktisch gleich häufig verwendet, einzig "*strong girl*" war etwas populärer als die anderen.

Im Durchschnitt wurden gleich viele Vorschläge von starken wie von schwachen Agenten angenommen. Insgesamt wurden gegen Ende mehr Vorschläge als zu Beginn akzeptiert.

Es war außerdem bei der Gruppe eine Leistungssteigerung hinsichtlich folgender Aspekte zu beobachten:

- der Anzahl der richtigen Lösungen,
- deren Gewichtung und
- der Lösungsgeschwindigkeit.

Den größten Lernfortschritt machten die Introvertierten. Dies lässt die Autoren der Studie vermuten, dass sie nach der Strategie "Arbeite am meisten mit deinem Lieblingsagenten, benutze aber auch alle anderen" vorgegangen seien.

Insgesamt kommen Hietala und Mitarbeiter zu dem Schluss, dass es vorteilhaft sei, aus einer Gruppe von LC wählen zu können. Die "zögerliche" Stimme der schwachen Agenten gebe weniger guten Schülern den Mut, eigene Lösungsansätze auszuprobieren. Um Eintönigkeit zu vermeiden, sollten die Agenten jedoch mehr die auf Handlungen der Benutzer reagieren. Schließlich sollte kein Agent "perfekt" funktionieren, sondern manchmal auch "faul" oder "selbstsüchtig" handeln, um den Benutzer zu selbständigem Denken zu motivieren.

## Literatur

Goodman et al.: Encouraging Student Reflection and Articulation using a Learning Companion. Aus: International Journal of Artificial Intelligence in Education, (1998), 9, 237-255.

Hietala et al.: The Competence of Learning Companion Agents. Aus: International Journal of Artificial Intelligence in Education, (1998), 9, 178-192.