

**Universität Augsburg**

Institut für  
Mathematik

---

---

Ulrich Fahrner, Antony Unwin

**Adaptive Verfahren zur Analyse und Verbesserung realer  
Lehr-Lern-Systeme**

---

Preprint Nr. 033/2007 — 17. Juli 2007

Institut für Mathematik, Universitätsstraße, D-86 135 Augsburg

<http://www.math.uni-augsburg.de/>

---

**Impressum:**

*Herausgeber:*

Institut für Mathematik

Universität Augsburg

86135 Augsburg

<http://www.math.uni-augsburg.de/forschung/preprint/>

*ViSdP:*

Antony Unwin

Institut für Mathematik

Universität Augsburg

86135 Augsburg

*Preprint:* Sämtliche Rechte verbleiben den Autoren © 2007

Ulrich Fahrner und Antony Unwin

## **Adaptive Verfahren zur Analyse und Verbesserung realer Lehr-Lern-Systeme**

### **1. Von der Komplexität von Lehr-Lernsystemen**

„Es ist die Logik, mit der man beweist;  
es ist die Intuition, mit der man erfindet.“  
*Henry Poincaré*

Lernen ist wohl der komplexeste Vorgang, den das menschliche Gehirn hervorbringt, denn es umfasst das Speichern von Informationen, das Kombinieren von Daten zu völlig neuen Zusammenhängen, das Reflektieren von Gelerntem und schließlich das Einordnen des Gelernten in das eigene Sein bis hin zum Zurückschauen und Erforschen auf das biologische System „Gehirn“, welche das eigene Bewusstsein hervorgebracht hat. Davon ausgehend steht die Lehr-Lernforschung vor dem Problem, diese Vorgänge zu analysieren, Modelle dafür zu finden und daraus optimale Rahmenbedingungen und Methoden zu entwickeln, die dem Lernenden die Chance geben, möglichst effektiv und mit Freude zu lernen.

Aus dieser Überlegung heraus scheint es fast unmöglich, das Lernen quantitativ zu erforschen und mit wenigen Variablen zu beschreiben. Das Einzige, was bleibt, ist neue Methoden des Lehrens aus der Erfahrung heraus zu entwickeln. Dieses Vorgehen ist im besten Sinne des Wortes „empirisch“ (griechisch „auf Erfahrung beruhend“). Die Forschungsmethoden und mathematischen Verfahren, die der Komplexität des Lernvorgangs gerecht werden, müssen einzig und allein auf die Forschungsfrage und den Beobachtungsgegenstand ausgerichtet sein, seien sie noch so komplex und schwierig zu handhaben. Implizite Festlegungen durch die Wahl von Forschungsverfahren müssen dem Forscher bewusst und sachlogisch begründbar sein. Dazu gehört etwa die Frage, ob ein Problem diskret (wie z. B. eine Notenskala) oder stetig (wie z. B. die Zeitskala in einer Unterrichtsstunde) ist. Der Forscher muss sich auch darüber im Klaren sein, in welchem mathematischen Raum sein Modell „lebt“: Ist es von Natur aus ein chaotischer Vorgang, ein diskontinuierlicher Vorgang oder ein einfacher linearer Zusammenhang, der über die Grenzen der Untersuchung hinaus extrapoliert werden kann? Die gewählten beobachteten Größen, welche den Lernvorgang beschreiben sollen, müssen so weit wie möglich den vollständigen Vorgang beschreiben. Eine „Stückelung“ in Teilsysteme, deren Verhalten man nicht genau kennt und die das Gesamtsystem nicht disjunkt zerlegen, führen dazu, dass Aussagen über die Teilsysteme keine Aussagekraft für das Gesamtsystem haben und wenig zur Theoriebildung beitragen können.

#### **1.1 Abbildung eines Lehr-Lernsystems in einen Datensatz**

Der Dreh- und Angelpunkt einer jeden empirischen Untersuchung ist die Abbildung eines realen Lehr-Lern-Phänomens durch die Datenerhebung in die Sprache der Mathematik. Die Realität wird durch die Abbildung in einen Datensatz in mathematische Zusammenhänge übersetzt; diese werden mithilfe von mathematischen Methoden ausgewertet, neu kombiniert und zu neuen Aussagen synthetisiert; diese müssen in die reale Welt rückübersetzt, d. h. in-

terpretiert werden. Durch diese Interpretation wird es möglich, Aussagen in einer realen Lehr-Lern-Situation zu untermauern. Eine zutreffende Interpretation von mathematischen Aussagen ist aber nur möglich, wenn ganz zu Beginn der Forschungsarbeiten die Abbildung in den Datensatz und die dabei gemachten impliziten Fehler klar sind und für diese maximale Grenzen angegeben werden können. Schränkt man sich hier von Anfang an zu stark ein, indem man z. B. eine zu kleine Klasse mathematischer Beschreibungsformen wählt, werden unter Umständen die entscheidenden Größen von der Beschreibung ausgeschlossen und führen so zu einem aussagelosen Modell.

Lernen ist – wie der wissenschaftliche Erkenntnisprozess – kein kontinuierlicher Vorgang, sondern gekennzeichnet von Sprüngen z. B. zwischen diskreten „Aha“-Erlebnissen, die nicht durch stetige Variablen dargestellt werden können. Daher ist der Lern- und Erkenntnisprozess von seiner Art her ein chaotischer diskontinuierlicher Prozess. Dies entspricht auch der Erfahrung vieler Lehrender in Schule und Universität. Der Lernprozess ist mit einfachen linearen stetigen mathematischen Modellen nur in wenigen Randbereichen ansatzweise beschreibbar. Mathematische Verfahren, die solche Vorgänge beschreiben können, wurden erst in den letzten Jahrzehnten entwickelt. Alle Daten müssen so im Modell verwendet werden, wie sie erhoben wurden, d. h. diskrete Variablen bleiben diskret, stetige Variablen bleiben stetig. Beispielsweise müssen Fragen in Fragebögen mit Auswahlantworten immer diskret ausgewertet werden. Die in vielen empirischen Untersuchungen gemachten Vereinfachungen, die nur der Rechenvereinfachung dienen und nicht aus dem Problem heraus begründet werden können, sind nicht zielführend, sondern entziehen der Untersuchung viel von ihrer wissenschaftlichen Aussagekraft.

Neben den rein mathematischen Werkzeugen zur Beschreibung des Lehr-Lernprozesses ist auch die wissenschaftstheoretische Herangehensweise in einem Umbruch begriffen. Durch Studien wie PISA werden Lernszenarien in verschiedenen Ländern für Politik und Gesellschaft vergleichbar. Diese begnügen sich immer weniger damit, von der Forschung zu erfahren, welche Lernszenarien nicht funktionieren, sondern möchten Antworten auf drängende Fragen einer Wissensgesellschaft. Viele Forscher im Lehr-Lernbereich nehmen diese Herausforderung an und orientieren sich bei der Konstruktion von konkreten Lernszenarien an der Herangehensweise der Ingenieurwissenschaften.

Durch die Kombination des Design-Based-Research-Ansatzes mit der Explorativen Datenanalyse mit dynamischen Systemansätzen aus dem Bereich der diskreten Mathematik ergeben sich neue Perspektiven für die Lehr-Lernforschung. Damit sollte es möglich sein, Innovationen in der Gestaltung konkreter Lehrszenarien zu schaffen, die auf konkreten empirischen Forschungsergebnissen beruhen. Dadurch eröffnet sich die Lehr-Lernforschung einen neuen Weg, Innovationen in der Lehre voranzutreiben. Ein konkretes Lehr-Lernszenario kann nur durch eine sehr große Anzahl von Dimensionen („Dimensionen“ im mathematischen Sinn) eindeutig charakterisiert werden. Diese Anzahl von Dimensionen übersteigt in einer realen Situation jede Anzahl von Variablen, die erhoben und in einem konventionellen statistischen Modell bearbeitet werden können. Dies liegt zum Teil daran, dass man nicht alle Variablen kennt, dass von Anfang an nicht klar ist, welche Variablen die gestellte Forschungsfrage beantworten können, und dass keine geeigneten Werkzeuge zur Messung dieser Variablen zur Verfügung stehen. Erschwerend kommt hinzu, dass durch den Messvorgang selbst und durch den Einsatz bestimmter Messwerkzeuge die Observablen (also die beobachteten Variablen)

verfälscht werden können und der Messvorgang für die Observablen nicht immer Teil der Theoriebildung ist – vgl. Hawthorne-Effekt (Mayo, 1933). Vor ähnlichen Problemen stand die Physik zu Beginn des 20. Jahrhunderts. Damals musste sich die Physik auch von dem unbeteiligten Beobachter, der keinen Einfluss auf das Messergebnis hat, und von deterministischen Erklärungsmodellen im atomaren Bereich trennen. Erst durch das Integrieren des Messvorgangs in die Theorie und die Wahl einer wesentlich größeren Klasse an statistisch mathematischen Modellen war es möglich, die Quantenmechanik zu entwickeln und bis dahin nicht erklärbare Phänomene zu beschreiben sowie für diese konkrete Voraussagen zu treffen. Startpunkt für das Entwickeln neuer Modelle und Beschreibungsformen für den Lernvorgang ist eine genaue Analyse von komplexen Datensätzen, da diese Modelle höchstwahrscheinlich eine große Zahl von Variablen enthalten, welche die Komplexität des Lernvorgangs beschreiben. Die Explorative Datenanalyse hat genau hier, nämlich in der Analyse von großen Datenmengen und multivariaten Datensätzen ihre Stärke.

## 1.2 Die Explorative Datenanalyse als Analysestrategie im Kontext des Design-Based-Research

Der Grundgedanke des „Design-Based-Research“-Ansatzes (DBR) im Lehr-Lernkontext ist, dass Lehrende und Lernende in ihren natürlichen Umgebungen beobachtet werden. Durch implementierte theoriegeleitete Lehrdesigns werden neue Praktiken und Theorien für das Lehren und Lernen hervorgebracht (Brown, 1992; vgl. auch Hug, Friesen & Rourke sowie Reinmann, in diesem Band). Durch den iterativ angewandten Erkenntnis- und Entwicklungsprozess von theoriegeleitetem Design, Implementation, Analyse, Re-Designs und schließlich durch die mit neuen Ideen angereicherten theoriegeleiteten Designs schließt sich ein Entwicklungszyklus. Das heißt in der Praxis: Vor dem Hintergrund theoretischer Überlegungen wird ein Lehr-Lernsystem entwickelt und in ein konkretes Lernszenario implementiert. Dieses Szenario eines Lehr-Lern-Systems wird im Feld praktisch erprobt und empirisch untersucht – mit quantitativen und qualitativen Methoden. Auf dieser empirischen Basis wird das Lernszenario optimiert und die Lernumgebung dadurch entsprechend verbessert (Joseph, 2004). Die Schritte zur Verbesserung der Lernumgebung und deren empirische Überprüfung führen über mehrere Iterationsschritte zu einem Erkenntnisgewinn für die Lehr-Lernforschung (Bell, 2004). Wie unten dargestellt, lässt sich der DBR-Ansatz in Form eines Zyklus darstellen.

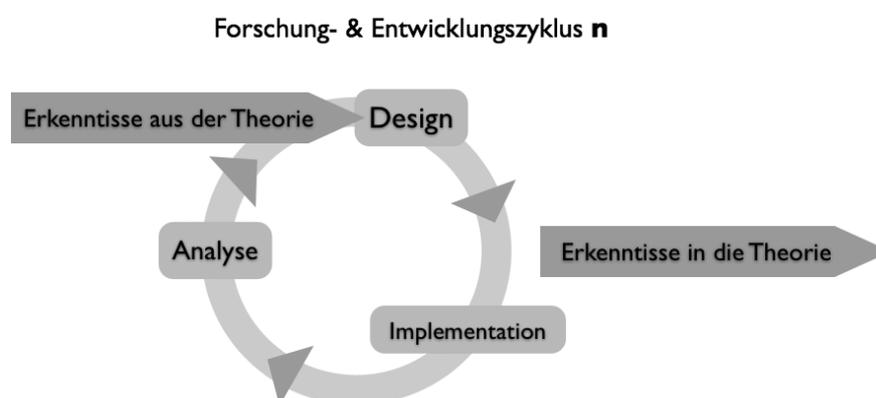


Abb. 1: n. Schritt des Iterativen Innovationsprozesses des DBR-Ansatzes

In dem Zyklus wechselt der Fokus des Entwicklungsforschers zwischen Theorie und Praxis. Ein vollständiger Entwicklungszyklus lässt sich daher wie folgt beschreiben:

- *Design*: Auf der Basis von theoretischen Modellen (aus der Lehr-Lernforschung) wird ein theoretisches Konzept für eine Lernumgebung erarbeitet. Dieses Konzept ist im ersten Iterationsschritt das „Design“ für ein neues Lehr-Lern-Szenario.
- *Implementation*: Diese Lernumgebung wird entsprechend diesem theoretischen Konzept entwickelt und unmittelbar in der Praxis eingesetzt, damit die theoretischen Ergebnisse in der Praxis auf die Probe gestellt werden können.
- *Analyse*: Die Lernumgebung wird nach der Implementierung in verschiedenen Praxiskontexten untersucht, wobei die praktische Umsetzung analysiert sowie die theoretischen Überlegungen des Konzepts für die Lernumgebung hinterfragt werden.
- *Re-Design: Design des zweiten Iterationsschritts*: Neben den Erkenntnissen aus der Analysephase gehen in diesem Schritt wieder theoretische Konzepte und aktuelle Ergebnisse aus der Lernforschung ein und wirken auf die Theoriebildung zurück.

Beim Durchlaufen dieser Phasen des Forschungs- und Entwicklungszyklus werden zwei unterschiedliche Entwicklungslogiken miteinander verbunden: Einerseits erfolgt in der Designphase eine bewusste Gestaltung des Lehr-Lernszenarios im Sinne eines Schöpfungsaktes (Schrage, 1999). In der Phase des Re-Designs kommt es andererseits im Sinne des Evolutionsprinzips zur Anpassung des Designs an die Rahmenbedingungen des Echtbetriebs. Beide Logiken lassen sich als zwei komplementäre Innovationsprozesse beschreiben (Gassmann & Enkel, 2006). Das Design-Based-Research ist vielmehr eine Strategie als eine Methode, denn sie lässt sich auf viele Forschungsgegenstände anpassen und verlangt stets, dass sich der Forscher Verfahren bedient, die an den Forschungsgegenstand angepasst sind. Dies bedeutet, dass auch im Schritt der Analyse nicht nach einem Kochrezept vorgegangen werden kann – im Gegenteil: Es werden wissenschaftliche Strategien benötigt, welche sich adaptiv in ihrer Methodenwahl an den Forschungsgegenstand anpassen. Die Explorative Datenanalyse (EDA) ist, wie das Design-Based-Research, eine adaptive Vorgehensweise. Ziel ist es, die Information in Datensätzen zugänglich und sichtbar zu machen, indem man statistische Modelle und Grafiken einsetzt, um Dateneigenschaften zu erkennen. Obwohl statistische Verfahren einen wichtigen Beitrag in der EDA leisten, spielt die „interaktive Grafik“ eine zentrale Rolle, weil sie in der Lage ist, unerwartete Einsichten zu gewähren und auf neue Ideen hinzuweisen. Die ist vor allem bei multivariaten Datensätzen von entscheidender Bedeutung, da sonst viele Zusammenhänge, die in den Daten liegen, unentdeckt bleiben. So ergänzen sich Grafiken und Modelle (im statistischen Sinne) gegenseitig. Ein Resultat, das einer Grafik entstammt, soll womöglich mit einem Modell überprüft werden und umgekehrt. Interaktive grafische Methoden sind ein besonders wirksamer Ansatz, da sie mehrere Ansichten gleichzeitig anbieten; daher kann man auf gewonnene Einsichten flexibel reagieren. Die interaktive Grafik liegt, wie Abbildung 2 (s. u.) zeigt, einerseits auf der Nahtstelle zwischen der Abbildung eines realen Problems in einen Datensatz und andererseits auf der Nahtstelle zwischen Datensatz und Modell.

### 1.3 Klassen statistischer Probleme

Seit den Arbeiten von John W. Tukey gehört das Suchen (die Exploration) neben dem Beschreiben (Deskription) und dem Schließen (Induktion) zu den Grundaufgaben der Statistik. Die daraus entwickelte Strategie der Statistik wird als Explorative Datenanalyse bezeichnet. Es liegt in der Natur eines derart komplexen und interaktiven Vorganges – wie der Suche nach einem statistischen Modell für einen realen Datensatz –, dass es sich nicht in ein kochrezeptartiges Schema pressen lässt. Das Leitbild, das Tukey für die Explorative Datenanalyse geprägt hat, ist das eines Detektivs, welcher ausgehend von einem Problem in den Daten interessante Strukturen und Besonderheiten aufdeckt, Hinweisen nachgeht und Hypothesen entwickelt (Tukey, 1962).

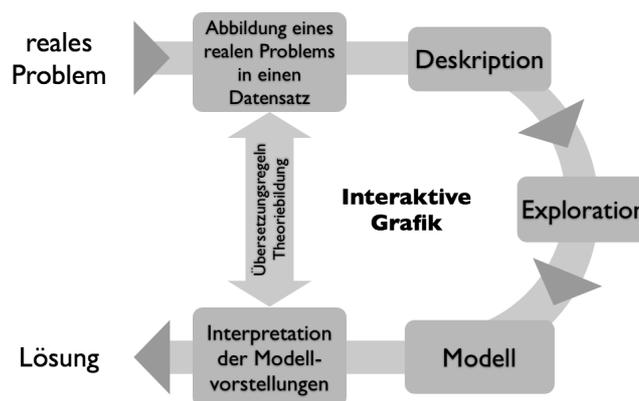


Abb. 2: Übersetzung eines realen Sachverhalts in die Sprache der Mathematik und Lösung mit Hilfe der Explorativen Datenanalyse.

Die deskriptive Statistik begnügt sich damit, die Verteilung eines Merkmals zu beschreiben. Die Explorative Datenanalyse geht einen Schritt weiter und versucht die Fragen zu klären, wie: „Was ist an einer Verteilung eines Merkmals ungewöhnlich oder bemerkenswert?“ und „Wo bieten sich Ansätze für ein statistisches Modell?“ Durch die Beantwortung dieser beiden Fragen ist es erst möglich, die volle Vielfalt und den mathematischen Reichtum der induktiven Statistik auf reale und komplexe Datensätze anzuwenden. Um eine reale Lehr-Lern-Situation zu analysieren und Ansatzpunkte für komplexe Modelle zu finden, die über Erkenntnisse von Laborexperimenten hinausgehen, ist es notwendig, umfangreiche Datenmengen zu sammeln, um die entscheidenden Daten für ein bestimmtes Lehr-Lernphänomen zu bekommen. Werden die mit großem Aufwand gesammelten Daten nur mit vorgefertigten Modellvorstellungen aus der Theorie ausgewertet und nicht detailliert untersucht, so bleiben in vielen Fällen weitergehende Informationen, die in den Daten stecken, unentdeckt. Die Exploration schließt sozusagen die Lücke zwischen Deskription und Induktion. Für den Betrachter, der sich noch nicht mit der Exploration beschäftigt hat, stellt sich natürlich die Frage, wie groß diese Lücke ist und bei welcher Art von Fragestellungen die Vorzüge der Exploration zum Tragen kommen und wie das Ganze konkret funktionieren soll. Dabei hilft es, die statistischen Fragestellungen in drei Problemklassen einzuteilen.

## Klasse 1: Auswertung von Laborexperimenten

*Definition (Laborexperiment): Ein Laborexperiment ist dadurch charakterisiert, dass unter kontrollierten Bedingungen in einem abgeschlossenen künstlichen Raum, wenige Variablen variiert werden, um eindeutige kausale Wirkungen zu untersuchen und zu quantifizieren.*

Bei der Auswertung von Laborexperimenten führen sachlogische Überlegungen zu einem qualitativen Zusammenhang und zu einem konkreten mathematischen Modell, dessen Parameter und Allgemeingültigkeit bestimmt werden müssen. Die Aufgabe der Statistik ist es, das Modell zu quantifizieren, d. h. die Größe der Parameter zu ermitteln und dafür Fehlerschranken anzugeben. Außerdem müssen durch die Versuchsplanung Aussagen zur Allgemeingültigkeit (Signifikanz) des Modells gemacht werden, sofern diese nicht schon durch sachlogische Überlegungen ermittelt wurden. Beispiele hierfür sind ein physikalisches Experiment der klassischen Mechanik, ein psychologisches Experiment in der Art der Versuche von Pawlow, Bestimmungen der Festigkeit im Bereich der Ingenieurwissenschaften usw. All diese Beispiele haben gemeinsam, dass die Randbedingungen und Fragestellungen klar durch das Problem vorgegeben sind.

Tab. 1: Charakterisierung von Laborexperimenten

	Größenordnung	Beispiel: Freier Fall
Anzahl der Fälle	wenige	25
Anzahl der Variablen	wenige	2
Modell	aus der Theorie bekannt	$g = 2h/t^2$

## Klasse 2: Auswertung von Feldexperimenten

*Definition (Feldexperiment): Ein Feldexperiment ist dadurch charakterisiert, dass unter teilweise kontrollierten Bedingungen in einem abgeschlossenen natürlichen Raum (Feld: Althochdeutsch für weites Land und für abgezaunte Weide), Variablen beobachtet, um ihre Wirkungen zu untersuchen und zu quantifizieren.*

Feldexperimente, die mit klassischen Methoden ausgewertet werden, sind gekennzeichnet durch relativ übersichtliche Datensätze. Das bedeutet, dass sie bestenfalls aus sehr vielen Fällen, aber nur aus sehr wenigen Variablen mit wenigen Kategorien bestehen, sodass die Fragestellungen schon relativ konkret und klar sind. Durch Vorüberlegungen aus Theorie und/oder Pilotexperimenten kann sichergestellt werden, dass die betrachteten Variablen das Feldexperiment vollständig beschreiben und die nicht benutzten Informationen für das Ergebnis irrelevant sind. Es sind zu Beginn der Auswertung sowohl die Modellbildung und die dabei gemachten Fehler als auch Ansätze für die Interpretation bekannt. Fragen in der Art „Welche Informationen liegen außerhalb der konkreten Modellvorstellung in einem multivariaten Datensatz vor?“ können nur schwer beantwortet werden. Zusammengefasst kann man sagen, dass so zwar Hypothesen bestätigt, aber kaum neue Hypothesen generiert werden können. Feldexperimente zeichnen sich dadurch aus, dass in Wissensgebieten, in denen es schon relativ klare Modellvorstellungen gibt, die Modellparameter relativ präzise bestimmt werden können und das resultierende Ergebnis Allgemeingültigkeit besitzt.

Tab. 2: Charakterisierung von Feldexperimenten

	Größenordnung	Beispiel: Die drei mendelschen Regeln
Anzahl der Fälle	viele	28000
Anzahl der Variablen	mittel	6
Modell	Ansatzpunkte aus Theorie bekannt	kombinatorische Modelle

### Klasse 3: Untersuchungen in der realen Welt

*Definition (Untersuchungen in der realen Welt): Eine Untersuchung in der realen Welt ist dadurch charakterisiert, dass unter beobachtbaren aber nicht zu kontrollierenden Bedingungen Variablen beobachtet werden, um ihre Wirkungen zu untersuchen und zu quantifizieren.*

Der zu untersuchende Datensatz ist unübersichtlich. Vermutungen über qualitative Zusammenhänge sind schwierig, es sind nur wenige, eher diffuse Randbedingungen vorgegeben; die Fragestellungen sind wenig konkret; man befindet sich oft auf wissenschaftlichem Neuland; man hat kaum oder keine Ideen und Anhaltspunkte für Hypothesen. Fragestellungen der Klasse 3 lassen sich mit den Werkzeugen der Explorativen Datenanalyse statistisch bearbeiten, indem man diese mit Hilfe der Exploration in Probleme der Klasse 2 zerlegt und diese schließlich in Probleme der Klasse 1 überführt. Konkrete Lehr-Lern-Szenarien, die untersucht werden sollen, sind häufig der Klasse 3 zuzuordnen. Die Kunst bei diesen Problemen besteht nun darin, das Gesamtsystem eines realen Lehr-Lern-Systems in Subsysteme zu unterteilen, die sich nicht gegenseitig beeinflussen und deren Wirkmechanismen sich durch Superposition mit dem Wirkmechanismus des Gesamtsystems verknüpfen lassen. Das Unterteilen in Subsysteme muss sowohl datenanalytisch als auch sachlogisch begründet und untermauert werden können. Dadurch wird das willkürliche „Fischen“ nach Daten ausgeschlossen.

Tab. 3: Charakterisierung von Untersuchungen in der realen Welt

	Größenordnung	Beispiel: PISA 2000	Beispiel: Eine Unterrichtsstunde
Anzahl der Fälle	wenige (viele)*	180000	Klassenstärke
Anzahl der Variablen	mittel (viele)*	unbekannt	unbekannt
Modell	unbekannt	unbekannt	unbekannt

\* Mit rechnergestützten Erhebungsmethoden ist auch möglich eine sehr große Anzahl von Fällen mit vielen Variablen und hoher Qualität zu beobachten. Beispielsweise können bei E-Learning-Plattformen die Logdaten des Servers und damit die Lernwege von den Teilnehmern ausgewertet werden.

## 2. Eine Beispiel für das Arbeiten mit EDA

Kennzeichnend für interaktive Analysen mit EDA ist die Schnelligkeit und Flexibilität. Zur Erläuterung wird ein Datensatz betrachtet, der aus dem vertraulichen Bericht von Florence Nightingale an die britische Regierung aus dem Jahre 1858 stammt über die Mortalität der Soldaten im Krim Krieg ([www.florence-nightingale-avenging-angel.co.uk](http://www.florence-nightingale-avenging-angel.co.uk)). Dieser Datensatz außerhalb des Lehr-Lern-Kontextes wurde gewählt, um zu zeigen wie man Daten aus einer

realen Situation ohne festgelegten Versuchsplan auswerten kann. Außerdem wird durch die multivariate Ansicht dieses Datensatzes deutlich, wie durch eine ebensolche Betrachtungsweise des Datensatzes Fragen zu dessen Qualität untersucht werden können. Dieser Datensatz und die weiteren Erhebungen von Florence Nightingale hatten auch Einfluss auf die damalige Politik und gesellschaftliche Entwicklungen und zeigen somit auch die Kraft empirischer Untersuchungen. Ein Auszug dieses Datensatzes ist in Abbildung 3 wiedergegeben. Insgesamt sind die Daten von 63 Corps aufgeführt, welche über sieben Monate vom Oktober 1854 bis April 1855 auf der Krim stationiert gewesen sind.

Division and Corps		Average Strength	Total.				Remarks	
			Admitted into Hospital	Died in the Crimea, &c.	Sent to Scutari, &c.	Died at Scutari, &c.		Invalidated to England, &c.
2nd	30th Foot	522	934	108	308	93	99	
Division	55th "	695	1,462	61	265	96	100	
	62nd "	430	949	96	135	42	24	
	95th "	417	1,250	199	345	155s	114	
	41st "	684	1,323	104	320	94	81	
	47th "	637	1,223	91	280	71	102	
	49th "	655	1,071	66	274	90	89	
3rd	1st "	771	1,048	229	354	118	63	
Division	14th "	423	878	8	42	2	6	a)
	38th "	689	1,728	149	319	118	73	

Abb. 3: Auszug aus Tabelle B aus dem Bericht von Florence Nightingale über die Mortalität im Krim-Krieg<sup>1</sup>

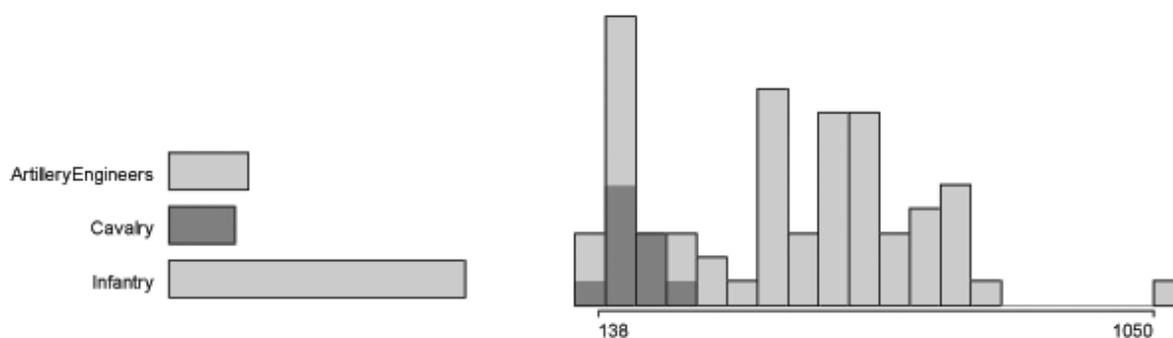


Abb. 4: Durchschnittliche Stärke des Corps und Corpstyp<sup>2</sup>

Abbildung 4 zeigt ein Histogramm der Stärken der Corps und ein Säulendiagramm für deren Typ. Es ist charakteristisch für die Interaktive Grafik, dass mehr als eine Grafik betrachtet und dass die Grafiken gelinkt (d. h. die Grafiken sind miteinander verbunden) werden. Die Kavallerie-Corps sind selektiert worden und es wird dadurch deutlich, dass diese Kavallerie-Corps alle kleiner waren. Man hätte auch in die andere Richtung linken können, das heißt z. B. die

<sup>1</sup> Die Spalten sind: Corps, durchschnittliche Stärke der Corps, in das Krankenhaus eingelieferte Soldaten, auf der Krim gestorbene Soldaten, nach Scutari verschickte Soldaten, in Scutari gestorbene Soldaten, nach England heimgekehrte Soldaten

<sup>2</sup> Die Kavalleriecorps sind selektiert worden und dunkel grau gekennzeichnet.

höheren Werte im Histogramm selektieren, um zu sehen, von welchem Corps-Typ sie stammen.

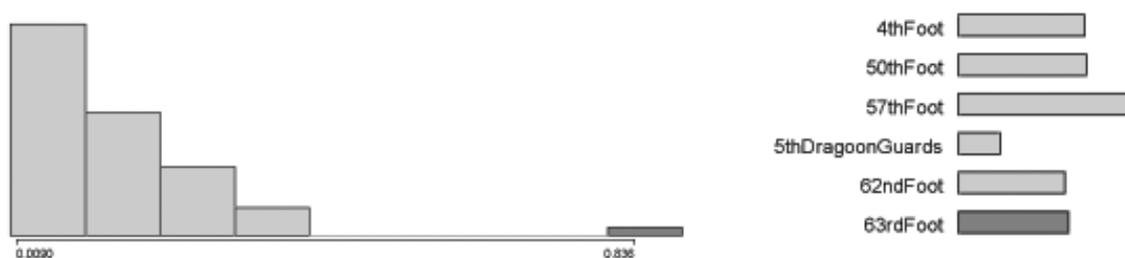


Abb. 5: Corps-Sterbeziffern auf der Krim (Histogramm) und ein Auszug aus dem Säulendiagramm der Corps-Stärken

Die Sterbeziffern der Soldaten innerhalb der Corps in der Krim selbst sind in der Abbildung 5 dargestellt. Der Extremwert wurde selektiert und im begleitenden Säulendiagramm als das 63. Foot Corp erkannt. Es wird nur ein Ausschnitt des Säulendiagramms gezeigt; das liegt daran, dass interaktiv eingezoomt (d. h. die Darstellung zeigt detailliertere Informationen) wurde, um sich auf den relevanten Teil konzentrieren zu können. Falls mehrere Corps selektiert worden wären, hätte man anschließend sortieren können – natürlich interaktiv! –, um die interessanten Fälle zusammenzustellen.

Das Hauptziel von Florence Nightingale war es, der Regierung die hohen Sterbeziffern im Krankenhaus in Scutari vor Augen zu führen.

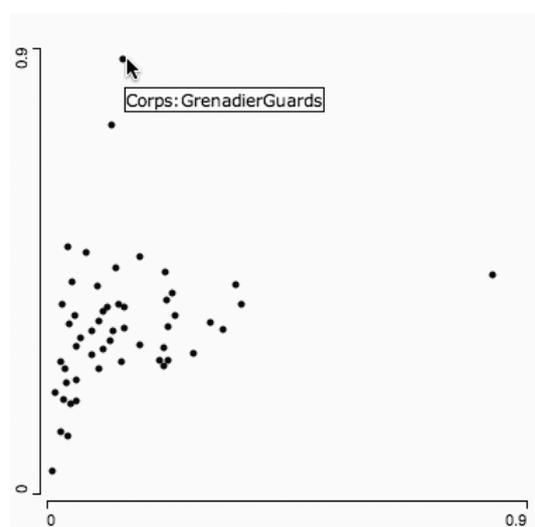


Abb. 6: Sterbeziffern der Corp-Soldaten in Scutari und auf der Krim<sup>3</sup>

Abbildung 6 stellt die Sterbeziffern im Scutari Krankenhaus und auf der Krim dar. Man erkennt, dass in allen Corps (außer dem schon erwähnten 63. Foot Corp) die Sterbeziffern in Scutari höher waren. Die Achsen sind gleich skaliert worden, um direkt vergleichen zu können. Zwei Corps hatten besonders hohe Sterbeziffern in Scutari. Die Abfrage zeigt, dass das Grenadier Guards Corp am härtesten getroffen wurde. Nach der Bewegung des Cursors auf das nächste Corps entdeckt man, dass dies das 93rd Foot Corp war. Die Möglichkeit, jedes

<sup>3</sup> Das Corps mit der höchsten Sterbeziffer in Scutari wurde abgefragt.

statistische Objekt in einer Grafik direkt abfragen zu können, ermöglicht eine sehr schnelle Zuordnung zwischen Diagramm und Daten. In diesem Fall wurde eine erweiterte Abfrage verwendet, um Information über Variablen, die nicht in der Grafik selbst erscheinen, sichtbar zu machen. Man hätte sich auch Werte für mehrere Variablen anzeigen lassen können.

Es ist leicht, die bis hierhin berichteten Analysen ohne Fragen zu akzeptieren. Wenn man sich aber darüber Gedanken macht, muss man aber an der Datenqualität zweifeln. Wie hätte man z. B. die „durchschnittliche“ Stärke eines Corps genau messen können? Sind die Statistiken unter den Umständen des Kriegs wirklich genau gesammelt worden? Wie sind die Todesfälle klassifiziert worden, die sich auf der Schifffahrt zwischen der Krimhalbinsel und Scutari ereignet haben (auf einer berüchtigten Fahrt sind 47 von 130 Patienten gestorben)? Um die Resultate richtig interpretieren zu können, ist die Hilfe entsprechender Experten mit dem nötigen qualitativen Hintergrundwissen notwendig. Auch hier kann die Interaktive Grafik hilfreich sein, um Kommunikation zwischen Datenanalysten und Historiker zu unterstützen. Dass dies tatsächlich funktioniert, hat sich in den letzten Jahren in unserer Arbeit immer bestätigt (Unwin, 2006).

### **3. Grundelemente der Explorativen Datenanalyse**

Das Hauptwerkzeug der Interaktiven Grafik ist der Computer. Mit leistungsfähigen Rechnern ist es möglich, sehr große Datensätze (Millionen von Fällen, viele Variablen) aus verschiedenen Perspektiven zu betrachten. „Perspektiven“ meint dabei verschiedene interaktive Plots (d. h. Grafiken und Diagramme mit interaktiven und über die Daten vernetzten Funktionalitäten), die alle miteinander „vernetzt“ sind. In den letzten Jahren wurde eine große Zahl von Plots in interaktiver Software umgesetzt und es wurden neue Arten von Plots entwickelt, welche die grundlegenden Werkzeuge der Interaktiven Grafik sind. Das geht von einfachen Streudiagrammen (siehe Abbildung 6), Histogrammen (siehe Abbildung 4,5) bis hin zu komplexen Darstellungen von Daten in Mosaikplots (siehe Abbildung 8) oder Parallel Koordinaten Plot (siehe Abbildung 9). Allen gemeinsam ist das so genannte „Highlighting“: Selektierte Daten werden in allen Plots gleichzeitig markiert. Eine Veränderung in einem Diagramm wirkt sich unmittelbar in allen anderen erstellten Diagrammen aus. Mit solchen Grafiken ist es möglich, Makro- und Mikrophenomene in den Daten bis hin zu jedem einzelnen Fall so darzustellen, dass Strukturen erkennbar werden, ohne dass man dabei den Gesamtüberblick verliert. Durch die Kombination einzelner Plots erhält man so schrittweise Erklärungsmuster unter Einbeziehung sachlogischer Überlegungen aus dem jeweiligen Wissensgebiet, aus dem die Daten stammen. Diese Erklärungsmuster verdichten sich Schritt für Schritt immer weiter, bis schließlich erste Ansatzpunkte für Hypothesen sichtbar werden. Die entwickelten Hypothesen können dann mit der schließenden Statistik bestätigt werden. Dabei stehen die volle Vielfalt und der mathematische Reichtum der Statistik zur Verfügung. Bei der Exploration geht man aber noch weiter. Man betrachtet nun die Residuen, die sich aus den statistischen Modellen ergeben, und untersucht diese auch wieder auf ihre Strukturen. Lassen sich Strukturen finden, so ergeben sich Ansatzpunkte für neue Hypothesen und verbesserte statistische Modelle. Je nach Qualität und Aussagekraft des Datensatzes kann es dazu kommen, dass der oben beschriebene Erkenntnisprozess auch schon vorher abbricht, d. h. dass der Informationsgehalt des Datensatzes nicht ausreicht, um schließende statistische Methoden anzuwenden. Bei vie-

len Fragestellungen, bei denen es zunächst darum geht, Wirkungszusammenhänge in einer Stichprobe (wie z. B. bei einem psychologischen, aber auch physikalischen Experimenten) herauszufinden, ist es durchaus ausreichend, aus den Wirkungszusammenhängen eine Erklärungshypothese zu generieren und diese durch theoretische Überlegungen zu untermauern. Dieses Vorgehen entspricht dem klassischen Vorgehen beim physikalischen Experiment. Dabei wird aus den in der Laborsituation erzeugten Daten (Stichprobe) eine These aufgestellt, diese in das vorhandene theoretische Gerüst physikalischer Erkenntnisse eingebunden, um dann in einem größeren Zusammenhang bestätigt zu werden.

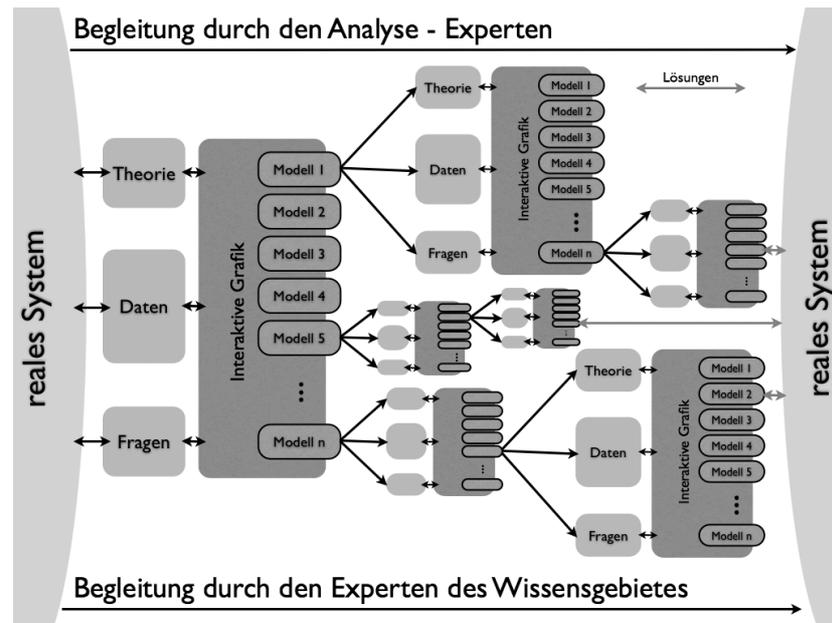


Abb. 7: Vorgehensmodell der Explorativen Datenanalyse

Die Philosophie der EDA, die Tukey (1962) vorlegte, ist durch die Entwicklung moderner Rechner und grafischer Software durchführbar geworden. Für diese Arbeitsweise sind schnelle, flexible Werkzeuge unerlässlich. Neuskalierungen, Einzoomen, Sortierungen, Formatierungen, Abfragen und – am allerwichtigsten – Linking müssen unmittelbar geschehen (Unwin, 1999). Standardgrafiken wie Histogramme, Säulendiagramme und Streudiagramme sind durch das Hinzufügen interaktiver Fähigkeiten durch ihre Implementation in grafische Software zu leistungsfähigen Werkzeugen geworden. Andere Grafiken, wie Mosaicplots für multivariate kategoriale Daten und Parallel Koordinaten Plots für stetige Daten, sind durch Interaktivität erst in der Praxis anwendbar geworden; siehe Abbildung 9. Es muss möglich sein, viele Fenster schnell zu zeichnen, sie übersichtlich zu verwalten und sofort aktualisieren zu können. Wenn tiefgehende Analysen, weiterführende Untersuchungen oder erkenntnisbringende Darstellungsänderungen notwendig sind, soll das mit direkten grafischen Zugriffen zügig durchgeführt werden.

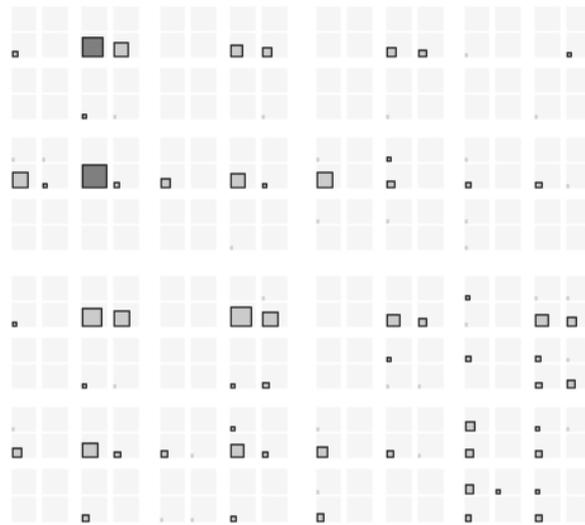


Abb. 8: Ein Mosaicplot für 8 binäre Variablen einer soziologischen Feldstudie von 665 Familien in Rochdale, England<sup>4</sup>

In der klassischen Statistik bieten Kommandozeilen-Oberflächen (d.h. der Nutzer muss jeden einzelnen Befehl wissen und eintippen um ihn ausführen zu lassen, es gibt keinerlei grafisch unterstützende Oberfläche) einen sinnvollen, strukturierten und mächtigen Zugang. Im Gegensatz dazu ist dieser Ansatz von den Konzepten der EDA zu weit entfernt, deshalb werden grafische Benutzeroberflächen benötigt, welche ein intuitives Arbeiten ermöglichen. Grafische Benutzeroberflächen haben aber auch Nachteile, wenn es darum geht, die gemachten Analyseschritte zu dokumentieren bzw. eine große Anzahl von Einstellungsmöglichkeiten aufzulisten. Diese Nachteile werden aufgewogen in dem Bereich, in dem es darum geht, intuitiv neue Informationen zu entdecken und Ansatzpunkte für Hypothesen zu finden; denn der Mensch „denkt“ nicht in Kommandozeilen sondern in Bildern.

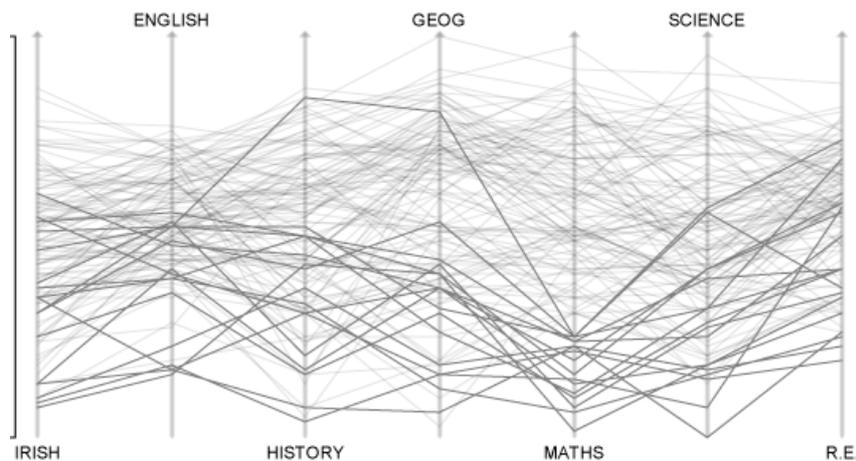


Abb. 9 Ein Parallel Koordinaten Plot der Noten von 126 irischen Schulkindern in sieben Fächern<sup>5</sup>

<sup>4</sup> Es gibt 256 mögliche Kombinationen und 15% der Familien (insgesamt 100) fallen in den zwei „gehighlighteten“ Gruppen (beide Eltern arbeiten, beide haben eine Ausbildung, keine andere Person im Haushalt arbeitet, kein Kleinkind, nicht asiatischer Herkunft), die Frauen unter 38 und über 38 kombinieren.  
Dunkel grau gekennzeichnet: selektierte Daten

Erst wenn Ansatzpunkte für Hypothesen gefunden sind, wird es notwendig, diese mit induktiven statistischen Verfahren zu belegen und die dafür geeigneten Kommandozeilenwerkzeugen (z. B. der Statistiksoftware R) zu belegen. Rechnerkapazitäten verbessern sich ständig, trotzdem werden sie nie allen Ansprüchen gerecht. Zurzeit können Datensätze mit einer Million Fälle mit interaktiven grafischen Methoden praktisch analysiert werden (Unwin et al., 2006). Für größere Datensätze werden andere Strategien gebraucht, wie z. B. Aufteilung in Untergruppen und die Verwendung von Stichproben. In dieser Hinsicht unterscheidet sich EDA von der klassischen Statistik kaum. Es ist schwer, die interaktive Vorgehensweisen in gedruckter Form wiederzugeben. Die Anzahl der betrachteten Grafiken, die ausprobierten Variationen, die Abfragen und die vielen verschiedenen Linkings tragen alle zum besseren Verständnis der Daten und zur Aufdeckung neuer Information bei.

### 3.1 Vorgehensmodell der Explorativen Datenanalyse

Das Verfahren der Explorativen Datenanalyse liegt mit seinem wichtigsten Werkzeug, der Interaktiven Grafik, auf der Nahtstelle zwischen der realen Fragestellung und der formalen Sprache der Mathematik und deren abstrakten mathematischen Modellen (siehe Abb. 2). Mit Hilfe der Explorativen Datenanalyse wird es bei vielen realen Problemen erst möglich, tiefgreifende mathematische Erkenntnisse in der Praxis anzuwenden und deren Aussagen für reale Fragestellungen zu nutzen. Der Kernleitsatz der Explorativen Datenanalyse ist dabei, sich die Daten aus verschiedenen Perspektiven „multivariat“ anzusehen und darin Strukturen zu erkennen. Dies ist in Abbildung 7 schematisch dargestellt. Der Gesamtvorgang, der als Explorative Datenanalyse bezeichnet wird, kombiniert dabei über mehrere Iterationsschritte folgende Elemente, deren Reihenfolge und Anwendungshäufigkeit stark problemabhängig ist und für die es kein Kochrezept gibt.

#### *Übersicht über die Daten gewinnen*

Durch die Verwendung verschiedener Interaktiver Grafiken und das Darstellen der Daten in verschiedenen Plots gewinnt man eine erste Übersicht über die Daten. Die Vernetzung der Plots untereinander und die Einbeziehung der Metadaten des Datensatzes zusammen mit Expertenwissen aus dem jeweiligen Wissensgebiet führen zu qualitativen Informationen über den Datensatz. Durch diese Kombination ist es oft möglich, ein Gesamtproblem in mehrere Teilprobleme zu zerlegen. Durch das explizite Verwenden von Expertenwissen können mitunter in diesem Schritt Modelle gefunden werden, die sich relativ leicht sachlogisch begründen und interpretieren lassen.

#### *Erstellung von Arbeitsmodellen*

In diesem Schritt werden die erkannten Strukturen aus dem vorhergehenden Schritt dazu verwendet, statistische Modelle auszuwählen und unter Einbeziehung der Daten eine konkrete Modellrealisation zu erstellen. Außerdem lassen sich hier oft schon grobe Abschätzungen des Gültigkeitsbereichs und Schranken für Fehlertoleranzen der Modelle angeben. In diesem

---

<sup>5</sup> Die Notenskala reicht von 14 bis 100. Alle Variablen sind gleichskaliert und die besten Noten sind oben. Die 17 Kinder, die in Mathe durchgefallen sind, sind ausgewählt worden. Sie waren meistens auch in den anderen sechs Fächern schwach, aber eines von den Kindern hatte sehr gute Noten in Geschichte (History) und Erdkunde (Geography).

Dunkel grau gekennzeichnet: selektierte Daten, grau gekennzeichnet: alle Daten.

Schritt sollte es in den meisten Fällen möglich sein, die Komplexität des Gesamtsystems und der einzelnen Subsysteme abzuschätzen und einzelne bearbeitbare Subsysteme vom Gesamtsystem abzuspalten. Man geht je nach Komplexität des Problems parallel vor und aggregiert mehrere Modellvorstellungen und kombiniert diese mit sachlogischen Überlegungen aus dem jeweiligen Wissensgebiet.

#### *Übersicht über das Residuum der Arbeitsmodelle gewinnen*

In diesem Schritt werden die Residuen der Arbeitsmodelle der Subsysteme mit den Werkzeugen der interaktiven statistischen Grafik betrachtet und Hinweise für die Verbesserung der Modelle gesucht. Die Modelle der Subsysteme werden dann zu einem Gesamtarbeitsmodell aggregiert und Interpretationen für das Gesamtmodell gesucht.

#### *Induktive Statistik anwenden*

Die gefundenen konkreten Modellrealisationen werden nun mit Hilfe der Möglichkeiten und Erkenntnisse getestet, welche die induktive Statistik bietet. Erkenntnisse aus Residuen und aus dem Vergleich verschiedener Arbeitsmodelle führen zu einer verbesserten Modellvorstellung. Diese fließt wieder in Arbeitsmodelle und die Modelle der Subsysteme in ein.

#### *Elemente iterativ anwenden*

Die oben genannten Elemente können sich viele Male in unterschiedlichster Reihenfolge wiederholen, um interpretierbare Lösungen zu entdecken, die zum Verständnis des realen Problems beitragen. Dies parallele und vielschichtige Vorgehen ist notwendig, um die multivariaten Strukturen in Datensätzen aufzuspüren. Der Begriff der Explorativen Datenanalyse (EDA) beschreibt also eine Strategie zur Problemlösung in einem realen Sachverhalt.

### **3.2 Freiheitsgrade in Lehr-Lernsystemen**

"Man soll die Dinge so einfach wie möglich machen, aber nicht noch einfacher." *Albert Einstein*

Bei allen Vorzügen der Explorativen Datenanalyse beim Umgang mit großen und multivariaten Datensätzen reicht dieses Analyseinstrument allein nicht aus, um konkrete Lernräume aufgrund empirischer Erkenntnisse zu gestalten und zu konstruieren. Das Hauptproblem liegt dabei in der großen Anzahl von Freiheitsgraden, die ein Lehr-Lernsystem besitzt. Konzepte aus den Ingenieurwissenschaften – bei denen es auch darum geht, für komplexe technische Problemstellungen konkrete Lösungen zu finden, ohne zu Beginn der Forschungsarbeiten alle Parameter und Einflussgrößen genau zu kennen – können dabei als Vorbild dienen. Hierbei wird zunächst durch empirische Erkenntnisse und theoretische Vorüberlegungen ein Rahmen für eine Konstruktion abgesteckt. Innerhalb dieses Rahmens wird dann durch Erfahrungswissen und den Einsatz qualitativer Erkenntnisse der Versuch einer konkreten Realisation der Konstruktion unternommen. Diese Erstkonstruktion (Prototyp) wird in einem iterativen Vorgang solange verbessert und optimiert, bis die Konstruktion die wichtigsten geforderten Eigenschaften erfüllen kann, die miteinander vereinbar sind.

Ein weiteres wichtiges Prinzip bei der Konstruktion von komplexen technischen Geräten kann im Bereich der Autoindustrie beobachtet werden. Jede Entwicklungsabteilung eines Autokonzerns konstruiert eine Vielzahl von Modellen und führt dazu entsprechende Designstudien

durch, die niemals in Serie gehen. Durch die Aggregation der gemachten Erfahrungen bei der Konstruktion der einzelnen Prototypen entstehen schließlich Vorserien-Prototypen, die schließlich in Serie gebaut werden. Mathematisch gesehen bedeutet dieses ingenieurmäßige Vorgehen nichts anderes, als das Anfangsproblem zunächst durch empirische Daten in ihren Freiheitsgraden oder Dimensionen zu reduzieren. In diesem so aufgespannten Unterraum verwendet der Ingenieur jetzt Erfahrungswerte und qualitatives Wissen, um die Konstruktion zu verbessern. Durch das Testen der möglichen Konstruktionen, die alle Bedingungen des Unterraums erfüllen, und deren Aggregation mit empirischen Mitteln, entsteht so wieder ein um Dimensionen verkleinerter Unterraum. So lässt sich das Gesamtproblem immer weiter reduzieren, bis eine konkrete Konstruktion entsteht, die sich in der Praxis bewähren müssen. Solche Entwicklungen sind nicht immer erfolgreich (in der Autobranche ist der Ford Edsel ein klassisches Beispiel). Auch Ideen aus DBR werden sich nicht immer als Erfolge in der Praxis herausstellen und man muss auf diese Möglichkeit vorbereitet sein, um flexibel darauf reagieren zu können. Bei einer so praktizierten Entwicklungsforschung gehört natürlich der Akt des Designs, der Konstruktion genauso zum Forschungsakt wie die Analyse. Beides sind Seiten ein und derselben Medaille.

Die oben beschriebene Aufteilung eines Gesamtproblems in kleinere Fragestellungen geringerer Dimension ist eine sehr spezielle Eigenschaft, die in jedem Einzelfall nachgewiesen werden muss. Diese Eigenschaft für alle Lehr-Lernsysteme allgemein nachzuweisen, ist völlig unmöglich, da viele interessante Phänomene im Bereich des Lernens gerade aus der Komplexität heraus entstehen. Durch die Aufteilung in kleinere Subsysteme geht aber gerade diese Komplexität verloren und kann daher nicht mehr untersucht werden. Es geht also darum, Subsysteme zu finden, die sich wirklich getrennt beobachten und untersuchen lassen. Das Zusammenfügen von Ergebnissen aus verschiedenen Subsystemen, die durch verschiedene Forschergruppen beobachtet wurden, ist nur dann zulässig, wenn der Nachweis geführt werden kann, dass weder die Wechselwirkung zwischen den Subsystemen, noch der steigende Grad der Komplexität einen Einfluss auf die Aggregation der Ergebnisse hat. Aufgrund dieser Eigenschaft komplexer Systeme wird auch ein Hauptvorteil des Design-Based-Research in Kombination mit der Explorativen Datenanalyse deutlich:

Die gefundenen Ergebnisse können leicht in den Gesamtkontext verortet werden und mithilfe von Expertenwissen (z. B. aus dem Pädagogik und Psychologie) interpretiert werden.

### **3.3 EDA und DBR: Zwei Strategien, die zusammenpassen**

Die Vorgehensweise von der Explorativen Datenanalyse grenzt sich klar von der klassischen Statistik ab, genauso wie sich das Design-Based-Research von der klassischen Experimentalforschung unterscheidet. Das Arbeiten in den Ingenieurwissenschaften, in der EDA und im DBA ist an einigen Stellen sehr ähnlich und manche Konzepte werden analog angewandt.

In der EDA fragt man die statistischen Objekte (Grafiken, Modelle) direkt ab, sowohl um Information zu sammeln als auch die Richtung der Analyse anzupassen. In DBR können neben quantitativen auch qualitative Daten direkt von den Teilnehmern mit einfließen und dadurch passen sich adaptiv die Forschungswerkzeuge an. EDA ist betont multivariat, d. h. mehrere Variablen werden gleichzeitig betrachtet und verbunden („linked“) analysiert. Man

ist also nicht an eine vorgegebene Struktur von Variablen gebunden, dies trifft in Grenzen auch für DBR zu. Bei der Darstellung von Daten in EDA werden flexible Sortierungsmöglichkeiten für Informationen (alternative Anordnungen von Kategorien oder Variablen in Grafiken) eingesetzt, um neue Einsichten zu gewinnen. Analog geht man auch im DBR vor und experimentiert mit verschiedenen Anordnungen, Prototypen und Lernszenarien. Ein übliches Vorgehen in einer EDA-Studie ist es, in die Daten zu „zoomen“, um sich auf eine Teilmenge zu konzentrieren. Bei dem DBR-Ansatz wird analog vorgegangen, wenn man qualitative Daten eines einzelnen Teilnehmers oder einer Gruppe näher untersuchen möchte. Der multivariate Aspekt von EDA bezieht sich nicht nur auf die typische Verwendung von mehreren Grafiken gleichzeitig, sondern auch auf die gleichzeitige Verfolgung mehrerer Fragestellungen. Es wird nicht streng linear gearbeitet, sondern auf verschiedenen Strängen parallel. Statt Antworten auf ein eng beschriebenes Ziel zu finden, wird eine allgemeine Strategie verfolgt, um mehr Information über eine bestimmte Fragestellung zu erhalten. In dieser Hinsicht zeigen sich wieder analoge Konzepte in EDA, DBR und Ingenieurwissenschaften. Diese ähnlichen und analogen Konzepte bilden sich immer dann heraus, wenn es um eine konkrete Konstruktion geht, denn es geht in allen drei Bereichen um die Entdeckung und Erfassung von Strukturen aus Daten, unter Einbeziehung des gesamten relevanten Hintergrundwissens. Der interaktive grafische Ansatz macht die Daten anderen zugänglicher und verbessert dadurch die Kommunikation zwischen Wissenschaftlern und anderen Beteiligten. Um Daten zu bearbeiten und zu verstehen, braucht man das notwendige Fach- und Metawissen. Das Konzept in der EDA bezieht sich auf Interaktion mit den Daten und die Interaktion mit den Forschern, die Wissen und Verständnis zum Fachgebiet beitragen können. Es hilft, die bekannte Furcht vor Zahlen und Formeln zu mindern und eine in beiden Richtungen stattfindende Kommunikation herzustellen. Wie in einem erfolgreichen Lernprozess, der Kommunikation sowohl zwischen Lernenden und Lehrenden als auch andersherum bedarf, möchte man sowohl Information aus den Daten als auch das Hintergrundwissen der Personen nutzen.

### **3.4 Studien und Daten**

Klassische statistische Methoden sind hauptsächlich entwickelt worden, um Daten aus wohldefinierten experimentellen Versuchen zu analysieren. Auf wissenschaftlichen Gebieten, wo Laborversuche (oder vergleichbares, wie in den Agrarwissenschaften) üblich sind, kommen solche Daten oft vor. Auf anderen Gebieten ist das eher selten, wie z. B. in den Sozialwissenschaften. Hier stehen mehr Beobachtungen als Messwerte zur Verfügung und es können die Bedingungen einer Studie nicht vollständig vorbestimmt und geregelt werden. In Bereichen wie der Lehr-Lernforschung und vielen psychologischen Fragestellungen ist der Messvorgang an sich nicht im strengen Sinn definierbar, sondern nur eine Metapher für das Strukturieren von Einzelbeobachtungen. Deshalb gelten die für eine klassische statistische Analyse notwendigen Annahmen nicht. Überraschenderweise hat das nicht nur Nachteile, sondern auch Vorteile.

Die Nachteile bei sozialwissenschaftlichen Fragestellungen beziehen sich auf die Resultate statistischer Tests. Mit diesen ist es nur möglich vorgegebene Hypothesen zu testen, die unter strengsten Auflagen durchgeführt worden sind. Die Interpretationen von Tests aus beobachteten Datensätzen müssen immer mit Einschränkungen erfolgen, denn die Verallgemeinerung

der Resultate auf andere Gruppen oder Situationen kann nur unter Vorbehalten gemacht werden. Es gibt aber nicht zu vernachlässigende Vorteile, die mit Design-Based-Research einiges gemeinsam haben. Die strenge Definition eines Laborversuchs führt dazu, dass wenige spezifische Daten für eine kleine Anzahl von Fällen erhoben werden - im Gegenteil: Bei Beobachtungsstudien ist es nicht ungewöhnlich, viele Daten für viele Fälle zu erheben. Die Chancen, auf interessante Ideen, Untergruppen oder Strukturen zu stoßen, sind umso größer. Voraussetzung hierfür ist, dass Werkzeuge zur Verfügung stehen, welche die Daten übersichtlich darstellen und gezielte Analysen unterstützen.

Mithilfe der Explorativen Datenanalyse kann man Hypothesen generieren. Obwohl die Gültigkeit solcher Hypothesen in anderen Studien überprüft werden muss, ist es manchmal möglich, aus Konsistenzgründen erste Plausibilitätstests durchzuführen. Konsequenzen der Hypothesen können mit anderen Variablen aus dem Datensatz untersucht werden. Wenn der Datensatz groß genug ist, gibt es zusätzlich die Strategie, ihn in zwei Gruppen zu trennen: Training und Test. Nur die Daten im Trainingsdatensatz werden zur Analyse freigegeben. Etwaige Hypothesen werden dann mit dem Testdatensatz überprüft. (Diese Strategie kann um noch einen Schritt verfeinert werden, indem man die Daten in drei Teile zerlegt: Training, Validation und Test. Der „Validation“-Teil (Validierung) wird dabei verwendet, um Modellformen zu überprüfen.) (Hastie, Tibshirani, Friedman, 2001).

#### **4. Zusammenfassung und Ausblick**

Die Verbesserung von Lehr-Lern-Systemen durch den Einsatz empirischer Forschungsergebnisse setzt voraus, dass der Konstruktionsvorgang mit in die wissenschaftliche Forschung einbezogen wird und sich Forschung nicht nur auf die Analyse begrenzt. Durch die Kombination der Forschungsstrategie „Design-Based-Research“ (DBR) und der Analysestrategie „Explorative Datenanalyse“ (EDA) stehen dem Forscher zwei adaptive Verfahren zur Verfügung, welche das Potential haben, die volle Komplexität des Lernens erfassen zu können, da sie sich flexibel dem Forschungsgegenstand anpassen.

Das isolierte Untersuchen von Mikrophänomenen in der Lehr-Lern-Forschung führt allein aus der grundsätzlichen Betrachtung der Freiheitsgrade des Systems in eine Sackgasse. Es sei denn, es kann nachgewiesen werden, dass sich die betrachteten Subsysteme nicht gegenseitig beeinflussen und keiner der wesentlichen Effekte des Lernvorgangs durch die Reduktion der Komplexität verloren geht. Die Unterscheidung von qualitativen und quantitativen Daten in der Lehr-Lernforschung ist meist rein willkürlich und verhindert durch eine ideologische Überfrachtung meist angemessene und belastbare Lösungen. Die Explorative Datenanalyse kann mit ihrem Hauptwerkzeug der interaktiven statistischen Grafik, sowohl die Abbildung eines realen Systems in die Sprache der Mathematik, als auch die Interpretation mathematischer Ergebnisse verbessern und versachlichen. Viele Erkenntnisse der Lehr-Lern-Forschung tragen zurzeit leider nicht zur Verbesserung der Lehre an Universität und Schule bei, da die dort erworbenen Erkenntnisse nicht in eine komplexe Realsituation eingeordnet werden können. In vielen Bereichen ist es nur möglich, zu sagen, was nicht geht, anstatt Aussagen zu Lösungswegen machen zu können.

Durch neue moderne mathematische Methoden wie der Explorativen Datenanalyse und des dazu passenden Design-Based-Research-Ansatz ergibt sich für die Forschung die Möglichkeit, reale Lehr-Lern-Systeme zu verbessern. Damit wird es in Zukunft möglich sein, dass die Weiterentwicklung von Schule und Universität nicht nur von jedem einzelnen Lehrenden intuitiv gemacht wird, sondern dass die Forschung ihren Teil dazu beiträgt reale Lehr-Lernsysteme zu verbessern.

**Hinweis:** In diesem Artikel ist die Software Mondrian von Martin Theus verwendet worden (<http://stats.math.uni-augsburg.de/Mondrian/>). Sie wurde für interaktive graphische Datenanalysen entwickelt.

## Literatur

- Bell, P. (2004). On the Theoretical Breadth of Design-Based Research in Education. *Educational Psychologist*, p243-253.
- Brown, A. L. (1992). Design Experiments: Theoretical and Methodological Challenges in Creating Complex Interventions in Classroom Settings. *Journal of the Learning Sciences*, 2(2), 141-178.
- Brown, J.S. & Hagel, J. (2005). From Push to Pull: The Next Frontier of Innovation. Some companies are learning how to take a more creative approach to mobilizing resources. *McKinsey Quarterly*, 2005 Number 3
- Gassmann, O. & Enkel, E. (2006): Open Innovation. Die Öffnung des Innovationsprozesses erhöht das Innovationspotential, in: *zfo*, 3/2006 (75. Jg.), S. 132-138
- Hastie, T.J., Tibshirani, R.J., Friedman, J. (2001): *The Elements of Statistical Learning*  
New York: Springer
- Joseph, D. (2004). The Practice of Design-Based Research: Uncovering the Interplay Between Design, Research, and the Real-World Context. *Educational Psychologist*, p235-242.
- Mayo, E. (1933) *The human problems of an industrial civilization* (New York: MacMillan)
- Reinmann, G. (2006). Nur „Forschung danach“? Vom faktischen und potentiellen Beitrag der Forschung zu alltagstauglichen Innovationen beim E-Learning. *Arbeitsbericht Nr. 14 der Medienpädagogik an der Universität Augsburg*.
- Schrage, M. (1999). *Serious Play. How the World's Best Companies Simulate to Innovate*. Boston: Harvard Business School Press.
- Tukey, J.W. (1962). The future of data analysis. *Ann Math Stat*, 33, 1-67.
- Unwin, A.R. (1999). Requirements for interactive graphics software for exploratory data analysis. *Computational Statistics*, 14, 7-22.
- Unwin, A.R., Theus, M. & Hofmann, H. (2006). *Graphics of Large Datasets*: Springer