

Birgit GRIESE, Michael KALLWEIT, Bochum

Lernverhalten und Klausurerfolg in der Ingenieurmathematik - Selbsteinschätzung und Dozentensicht

Will man Studierende zu Studienbeginn sinnvoll unterstützen, ist ein erster Schritt, die Faktoren für Klausurerfolg zu bestimmen. In unserer Untersuchung beschrieben 508 Studierende ihr Lernverhalten in sechs Kategorien. Die Daten wurden in Bezug auf Klausurpunkte und Studiengang ausgewertet. Zusätzlich wurden Dozenten gebeten, Klausurerfolg anteilig auf dieselben Kategorien zu verteilen. Die Ergebnisse liefern Einsichten zur Relevanz einzelner Kategorien und entkräften gängige Annahmen.

Einleitung

Der Übergang zu tertiärer mathematischer Bildung wird oft als problematisch beschrieben (z.B. Liston & O'Donoghue, 2009, Gueudet, 2008). Dies veranlasste verschiedene Untersuchungen, wie Studienanfänger unterstützt werden können (vgl. Hoppenbrock, Biehler, Hochmuth, & Rück, 2016), oft mit einem Fokus auf dem Lernverhalten (Dehling et al., 2014). Hier ist unsere Studie verortet.

Theoretische Einordnung und Forschungsfragen

Die Hürden, die Studierende in Mathematik zu Studienbeginn überwinden müssen, sind vielfältig (de Guzmán, Hodgson, Robert & Villani, 1998; Tall, 2004). Mathematische Kompetenz und schulische Qualifikationen bestimmen bereits zu etwa einem Drittel den akademischen Erfolg (Rach, 2014, S. 219). Als Hauptgründe für Studienabbruch gelten Leistungsprobleme und fehlende Motivation (Dieter, 2012; Heublein, 2010). Die vorliegende Studie trägt dazu bei, Einsichten zu gewinnen, wie das Lernverhalten mit dem Klausurerfolg zusammenhängt. Die Forschungsfragen lauten:

FF1: Welche Struktur haben die gesammelten Daten?

FF2a: Was sind die Verbindungen zwischen (selbsteingeschätztem) Lernverhalten und Klausurerfolg?

FF2b: Gibt es Unterschiede in den verschiedenen Studiengängen?

FF3: Lassen sich Cluster von Studierenden mit verschiedenem Lernverhalten finden? Zeigen sich Unterschiede bzgl. Klausurerfolg?

FF4: Inwiefern spiegeln die Einschätzungen der Dozenten die aus den Daten gewonnenen Ergebnisse wider?

Methodologie

Die Items zur Erfassung des Lernverhaltens decken die sechs Kategorien *Hausaufgaben*, *Vorlesungen*, *Übungen*, *Tiefenlernen*, *Oberflächenlernen* und *Anstrengung* ab. Die Items wurden aus Wild und Schiefele (1994), Himmelbauer (2009) sowie Trautwein, Lüdtke, Schnyder und Niggli (2006) nach Rach (2014) übernommen und auf einer 4-Punkt Likert-Skala bewertet. 508 Datensets aus drei Mathematik-Vorlesungen für verschiedene Ingenieur-Studiengänge wurden gesammelt. Zusätzlich schätzten 10 erfahrene Dozenten den prozentualen Einfluss der verschiedenen Kategorien auf den Studienerfolg ein. Für sie wurde eine siebte Kategorie (*Intelligenz / Begabung*) und eine offene achte hinzugefügt.

Zur Untersuchung der Daten wurden deskriptive Statistiken, explorative Faktoranalyse und Cronbach's α genutzt. Multiple lineare Regression wurde eingesetzt, um den Einfluss der verschiedenen Faktoren auf akademischen Erfolg zu beschreiben. Die kombinierten Item-Scores einer Skala dienten als Prädiktoren auf die Outcome-Variable *Klausurerfolg*. Eine k-means Clusteranalyse lieferte zwei Cluster, deren durchschnittliche Klausurpunkte berechnet wurden. Die Einschätzungen der Dozent*innen wurden mittels deskriptiver Statistiken, inklusive Medianen, kombiniert.

Ergebnisse

Faktor	# Items	α	% Varianz
<i>Hausaufgaben (H)</i>	7	.75	12%
<i>kontinuierliche Anstrengung (kA)</i>	7	.72	10%
<i>Vorlesungen (V)</i>	3	.72	7%
<i>Oberflächenlernen (O)</i>	4	.57	7%
<i>Tiefenlernen (T)</i>	5	.56	7%
<i>Übungen (U)</i>	3	.53	5%

Tabelle 1: Faktorbeschreibungen und Itemzahlen, aufgeklärte Gesamtvarianz 48%.

Die explorative Faktorenanalyse (Hauptkomponentenanalyse, Varimax-Rotation) zeigte, dass eine Skalenanpassung notwendig war. Die Anzahl der Faktoren wurde variiert; schließlich wurde entschieden, zwei Items zu tilgen und sechs Faktoren zu extrahieren. So konnten fünf der ursprünglich sechs Kategorien erhalten werden; ein Faktor wurde in *kontinuierliche Anstrengung* umbenannt (siehe Tabelle 1), da ihm auch Items zugeordnet wurden, die ursprünglich für *Tiefenlernen* vorgesehen waren. Das Sampling war gut (KMO=.84), und Bartlett's Test auf Sphärizität ($X^2(406)=3257.72$, $p=.000$) zeigte eine ausreichend große Korrelation zwischen den Items. Für drei der sieben Faktoren entspricht die interne Reliabilität den akzeptierten Standards ($\alpha > .7$)

Prädik-	BI, UTRM				MB			
	b	SE b	β	Sig.	b	SE b	β	Sig.
Konst.	25.95	18.09		.15	-	23.85		.21
<i>H</i>	21.50	4.16	.48***	.00	28.20	5.86	.47***	.00
<i>O</i>	-7.27	3.09	-.19*	.02	-3.03	4.57	-.06	.51
<i>T</i>	-7.46	4.16	-.15	.07				
<i>kA</i>	-2.77	4.01	-.06	.49				
<i>V</i>					5.80	3.23	.17	.08

Tabelle 2: Regressionsmodell mit vier bzw. drei Prädiktoren und Outcome Variable *Klausurerfolg*, Bauingenieurwesen und Umwelttechnik / Ressourcenmanagement (BI, UTRM) und Maschinenbau (MB), $R^2=.27$ bzw. $R^2=.32$.

Die Korrelationen zwischen den Faktoren lagen unterhalb von .48, was lineare Modellierung erlaubt. Zunächst wurden alle sechs Faktoren im Modell berücksichtigt, was Einsichten in die Bedeutung und Relevanz der einzelnen Faktoren ermöglichte: $R^2=.28$ (Bauingenieurwesen und Umwelttechnik / Ressourcenmanagement, BI, UTRM) bzw. $R^2=.32$ (Maschinenbau, MB). Für BI, UTRM wurde ein Modell mit vier Faktoren, für MB mit drei Faktoren präferiert, siehe Tabelle 2.

Versuche mit unterschiedlichen Anzahlen von Clustern führten zu einer Lösung mit zwei Clustern. Die Studierenden in Cluster 2 beschäftigen sich intensiver mit ihren *Hausaufgaben*, zeigen mehr *kontinuierliche Anstrengung*, bevorzugen *Tiefenlernen* vor *Oberflächenlernen* und nutzen die *Übungen* stärker – im Vergleich zu Cluster 1. Cluster 2 erzielte dann auch bessere Ergebnisse in den Klausuren (im Durchschnitt 52.70 für BI, UTRM und 77.70 für MB) als Cluster 1 (47.78 für BI, UTRM und 53.82 für MB).

Die Einschätzungen der Dozent*innen setzten *Hausaufgaben* an erste ($M=26.17$, $SD=13.65$, Median=22.50), *Anstrengung* an zweite Stelle ($M=15.60$, $SD=6.19$, Median=15.00) und *Intelligenz / Begabung* ans Ende.

Zusammenfassung und Diskussion

In Bezug auf die Struktur der Daten (FF1) konnten sechs Faktoren identifiziert werden, siehe Tabelle 1. Dies passt zum Design der Studie, jedoch wiesen nur drei Skalen die erforderliche interne Reliabilität auf.

Die Analyse des Einflusses des Lernverhaltens auf den Klausurerfolg (FF2a) betonte die Relevanz von *Hausaufgaben*, die den stärksten positiven Einfluss aufwies. Es gab auch Unterschiede (FF2b): Für BI, UTRM hatte *Oberflächenlernen* einen (signifikanten) negativen Einfluss, genau wie *Tiefenlernen* (wenn auch nicht signifikant). Für MB hat *Oberflächenlernen* nur einen schwachen (und nicht signifikanten) negativen Einfluss auf *Klausurerfolg*, und *Tiefenlernen* trägt gar nicht relevant bei. Erfreulicherweise hat

hier *Vorlesungen* einen positiven Einfluss. Insgesamt erklären die Faktoren aus unserem Modell 27% bzw. 32% der Outcome-Variable *Klausurerfolg*.

Die Clusteranalyse (FF3) liefert zwei Cluster: Studierende mit erwünschtem Lernverhalten (Cluster 2) und solche mit wenig empfehlenswertem Lernverhalten (Cluster 1). Es gibt den erwarteten Effekt auf *Klausurerfolg*, der jedoch bei Multiple-Choice-Fragen weniger ausgeprägt ist.

Die Dozenteneinschätzungen (FF4) zeigen als stärkste Abweichung zu unseren Erkenntnissen die hohe Einschätzung von *Anstrengung*. Die hohe Relevanz der *Hausaufgaben* auf *Klausurerfolg* scheint allgemein akzeptiert. Dementsprechend sollten auf Aufgaben Zeit und Mühe verwendet werden.

Literatur

- Dehling, H., Glasmachers, E., Griese, B., Härterich, J., & Kallweit, M. (2014). MP² - Ma-the/Plus/Praxis, Strategien zur Vorbeugung gegen Studienabbruch. *Zeitschrift für Hochschulentwicklung*, 9(4), 39–56.
- Dieter, M. (2012). *Studienabbruch und Studienfachwechsel in der Mathematik: Quantitative Bezifferung und empirische Untersuchung von Bedingungsfaktoren* (Dissertation). Universität Duisburg-Essen.
- de Guzmán, M., Hodgson, B. R., Robert, A., & Villani, V. (1998). Difficulties in the passage from secondary to tertiary education. In G. Fischer & U. Rehmann (Hrsg.), *Proceedings of the ICM. Documenta Mathematica Extra Volume III* (pp. 747–762). Rosenheim: Geronimo.
- Gueudet, G. (2008). Investigating the secondary–tertiary transition. *Educational Studies in Mathematics*, 67(3), 237–254.
- Heublein, U., & Barthelmes T. (2010). Woran Studierende scheitern - Die Studienstrukturreform führt zu einer Verschiebung bei den Ursachen für einen Studienabbruch. *HIS Magazin*, (2), 5–7.
- Himmelbauer, M. (2009). *Das neue Prüfungssystem im Medizincurriculum Wien: Promotor oder Hindernis für bedeutungsorientiertes Lernen?* (Dissertation). Universität Wien.
- Hoppenbrock, A., Biehler, R., Hochmuth, R., & Rück, H.-G. (Hrsg.). (2016). *Lehren und Lernen von Mathematik in der Studieneingangsphase: Herausforderungen und Lösungsansätze*. Wiesbaden: Springer Spektrum.
- Liston, M., & O'Donoghue, J. (2009). Factors influencing the transition to university service mathematics: part 1, a quantitative study. *Teaching Mathematics and its Applications*, 28(2), 77–87.
- Rach, S. (2014). *Charakteristika von Lehr-Lern-Prozessen im Mathematikstudium: Bedingungsfaktoren für den Studienerfolg im ersten Semester* (Dissertation). Christian-Albrechts-Universität, Kiel.
- Tall, D. O. (2004). Building theories: The three worlds of mathematics. *For the Learning of Mathematics*, 24(1), 29–33.
- Trautwein, U., Lüdtke, O., Schnyder, I., & Niggli, A. (2006). Predicting homework effort: Support for a domain-specific, multilevel homework model. *Journal of Educational Psychology*, 21(1), 11–27.
- Wild, K.-P., & Schiefele, U. (1994). Lernstrategien im Studium. Ergebnisse zur Faktorenstruktur und Reliabilität eines neuen Fragebogens. *Zeitschrift für Differentielle und Diagnostische Psychologie*, 15, 185–200.