SEEQ-DE

Konstruktion und Überprüfung einer deutschsprachigen Adaption des Instruments „Student Evaluation of Educational Quality“ (SEEQ; Marsh, 1982, 2007)

Martin Daumiller
Universität Augsburg

Robert Grassinger
PH Weingarten

Tobias Engelschalk
Universität Augsburg

Markus Dresel
Universität Augsburg

Zusammenfassung: Berichtet wird die Konstruktion und Überprüfung einer deutschsprachigen Adaption des Fragebogens „Student Evaluation of Educational Quality“ (SEEQ) von Marsh (1982, 2007), ein umfassend überprüfbares und international etabliertes Instrument zur Erfassung von Studierendenurteilen der Lehrqualität. Es wurde übersetzt, geringfügig erweitert und anhand einer Stichprobe von 76 687 Studierendenurteilen zu 3 660 Lehrveranstaltungen überprüft. Interne Konsistenzen und Intraklassenkorrelationen indizierten eine hohe Messgenauigkeit. Faktorenanalysen bestätigten die im SEEQ unterschiedenen Dimensionen. Neben den Produktfaktoren (Lernzuwachs, Gesamtbeurteilung) ließen sich als Faktoren des Lehrhandelns Engagement, Stoffstrukturierung und -präsentation, Aktivierung der Studierenden, Sozialklima, Stoffbreite, Leistungsbeurteilung und Aufgaben wie im Originalinstrument unterscheiden. Mit der Adaption wird studentische Beiträge als optionaler Faktor vorgeschlagen. Das Instrument erwies sich als messinvariant über verschiedene Veranstaltungsformen hinweg. Insgesamt legen die Ergebnisse nahe, dass mit der deutschsprachigen Adaption des SEEQ die Qualität hochschulischer Lehre international anchlussfähig und mit hoher Güte erfasst werden kann.

Schlüsselwörter: Lehrqualität, Lehrerfolg, Studierendenevaluationen, SEEQ

Construction and Confirmation of a German Adaption of the Student Evaluation of Educational Quality Questionnaire (SEEQ)

Abstract: The Student Evaluation of Educational Quality Questionnaire (SEEQ) by Marsh (1982, 2007) was adapted to German and tested using assessments from 76,687 students in 3,660 university courses. Internal consistencies and intraclass correlations indicated a high reliability. Two-level CFAs and ESEM analyses confirmed the separability of all original SEEQ dimensions: learning and overall as product factors, and enthusiasm, organization / clarity, group interaction, individual rapport, breadth, examinations / grading, and assignments / readings as factors on the level of instructional behaviors. In this adaption, we additionally proposed student contributions as an optional factor (the extent to which contributions of fellow students are considered helpful, and whether they are effectively controlled by the instructor), especially for contexts – such as those found in Germany – where student-directed teaching methods are prevalent. Additionally, we expanded the overall course rating by adding two items using a grade scale. These two adaptations are optional, and the scale worked equally well without them. We could confirm measurement invariance across different types of courses. Taken together, our findings indicate that the German adaption of the SEEQ measures teaching quality in accordance with established testing standards

Keywords: educational evaluation, students' evaluations of teaching (SET), teaching effectiveness

© 2021, Hogrefe. The official citation for this manuscript is: **Daumiller, M., Grassinger, R., Engelschalk, T. & Dresel, M. (2021). SEEQ-DE: Konstruktion und Überprüfung einer deutschsprachigen Adaption des Instruments „Student Evaluation of Educational Quality“ (Marsh) [Construction and Confirmation of a German Adaption of the Student Evaluation of Educational Quality Questionnaire (SEEQ)]. *Diagnostica*. Advanced online publication. <https://doi.org/10.1026/0012-1924/a000274>.** This paper is not the copy of record and may not exactly replicate the final, authoritative version of the article. The final article will be available, upon publication, via its DOI.

Die Evaluation der Qualität von Lehrveranstaltungen durch Studierende ist ein zentrales Element der Qualitätssicherung im Hochschulbereich und an den meisten Hochschulen nicht mehr wegzudenken, insbesondere da sie ein wichtiges Feedback zur Verbesserung der Hochschullehre bietet (Spinath et al., 2018; Spinath & Stehle, 2011). Lehrqualität ist multifaktoriell und umfasst sowohl Verhaltensweisen der Lehrenden als auch Ergebnisse auf Studierendenseite, wobei zu einem umfassenden Verständnis beide Merkmalsgruppen – also Prozess- und Produktmerkmale der Lehrqualität – berücksichtigt werden sollten (Abrami, d’Apolonia & Rosenfield, 2007; Marsh, 2007; Rindermann, 2009). Hierbei wird angenommen, dass bestimmte Dimensionen des Verhaltens der Lehrenden für die Prozessqualität der Lehre bedeutsam sind (Döring,

2005; Feldman, 1976). Auf der Produktebene wird argumentiert, dass gute Lehre zu einem Zuwachs von Wissen und Fertigkeiten und langfristig zu Berufserfolg und einer erfolgreichen Lebensbewältigung führt (Helmke, 1996). Entsprechend sollte sich qualitätsvolle Lehre in günstigen Bewertungen sowohl von Prozess- als auch Produktmerkmalen widerspiegeln, wobei diese Aspekte in einem positiven Zusammenhang stehen. Umfassend belegt ist, dass Studierende Bewertungen von Prozess- und Produktmerkmalen der Lehrqualität valide vornehmen können (Stehle & Spinath, 2011).

Studentische Lehrveranstaltungsevaluationen weisen international eine lange Tradition auf. Seit den 1990er Jahren werden verstärkt auch im deutschsprachigen Raum multifaktorielle Fragebogeninstrumente zur Erfassung von Lehrqualität herangezogen (ESM 1). Diese Instrumente erfüllen oft hohe Standards der Messgüte und gelten als im Praxiseinsatz bewährt. Dazu zählen häufig auch standortspezifische Fragebögen, die auf Grundlage generellerer Fragebögen adaptiert und psychometrisch überprüft wurden (Sengewald, 2016). Nicht zuletzt, um die Qualität dieser standortspezifischen Instrumente zu untersuchen (z. B. bei Untersuchungen der konvergenten Validität) und die Anschlussfähigkeit der erhaltenen Befunde an einschlägige internationale Arbeiten zu wahren, sind auch deutschsprachige Versionen international weit verbreiteter Evaluationsbögen notwendig.

Ein international besonders häufig verwendetes Instrument zur Erfassung von Studierendenurteilen der Lehrqualität ist der Fragebogen „Student Evaluation of Educational Quality“ (SEEQ; Marsh, 1982, 2007). Die Messgüte dieses Instruments gilt durch eine große Zahl publizierter Studien als umfassend belegt – auch über die Hauptgütekriterien hinausgehend, etwa in Bezug auf Ökonomie und Testfairness (Marsh, 2007). Der SEEQ ist damit ein international etabliertes und akzeptiertes Instrument in der Praxis der Evaluation von Lehrqualität im Hochschulbereich (Marsh & Roche, 1997). Daneben wird der SEEQ in einer Vielzahl internationaler Forschungsarbeiten eingesetzt, beispielsweise um Lehrqualität in Abhängigkeit von Merkmalen der Lehrenden (z. B. Motivation) oder des Kontexts (z. B. Institutionsformen) zu analysieren, Veränderungen der Lehrqualität zu erforschen oder die Wirkung von Interventionen zu untersuchen (Marsh, 2007). Somit ist dieses Instrument nicht nur für die Evaluationspraxis, sondern auch für internationale Forschung zur Lehrqualität bedeutsam.

Im SEEQ unterscheidet Marsh (2007) insgesamt neun Dimensionen. Als Indikatoren für den Lehrerfolg auf Produktebene sind (1) der *Lernzuwachs* der Studierenden (learning / value) und (2) die *Gesamtbeurteilung* (overall) der Studierenden enthalten. Als Faktoren des Lehrhandelns auf Prozessebene werden (3) *Engagement der Lehrperson* (instructor enthusiasm), (4) *Stoffstrukturierung und -präsentation* (organization / clarity), (5) *Aktivierung der Studierenden* (group interaction), (6) *Sozialklima* (individual rapport), (7) *Stoffbreite* (breadth of coverage), (8) *Leistungsbewertung* (examinations / grading) und (9) *Aufgaben* (assignments / readings) erfasst. Marsh und Dunkin (1992) evaluierten den Inhalt des SEEQ hinsichtlich der von Feldman (1976) und Fincher (1985) berichteten, übergreifenden Prinzipien des Lehrens und Lernens in tertiären Einrichtungen und fanden, dass die erfassten Dimensionen der Lehrqualität diese Prinzipien adäquat adressieren. Zwar gibt es in der Fachliteratur eine Diskussion über die Anzahl und Qualität der Dimensionen von Lehrqualität im Allgemeinen (Spooren, Brockx & Mortelmans, 2013), sodass auch andere Faktoren als jene des SEEQ herangezogen werden könnten – in Hinblick auf den SEEQ hat eine Vielzahl an Studien jedoch mittels Faktorenanalysen belegt, dass die genannten neun Dimensionen des SEEQ von Studierenden voneinander separierbar wahrgenommen und beurteilt werden (Marsh & Hocevar, 1991; vgl. aber auch Toland & De Ayala, 2005) und über verschiedene sprachliche sowie kulturelle Kontexte hinweg gültig sind (Marsh, 2007; Watkins, 1994). Auch

Correspondence concerning this article should be addressed to Martin Daumiller, Department of Psychology, University of Augsburg, Universitätsstr. 10, 86159 Augsburg, Germany; Martin.Daumiller@phil.uni-augsburg.de.

We have no known conflicts of interest to disclose. Wir danken Christian Eibl und Susanne Reeß für ihre Unterstützung bei der Planung und Durchführung der Lehrveranstaltungsevaluationen.

wenn Dozierende die Qualität ihrer eigenen Lehrveranstaltungen beurteilen, unterscheiden sie zwischen diesen Dimensionen (Marsh, Overall & Kesler, 1979). Eine multidimensionale und damit differenzierte Auffassung erscheint auch mit Blick auf die Rückmeldung spezifischer veränderbarer Aspekte der Lehre notwendig. Zahlreiche Studien erbrachten, dass jede der unterschiedlichen Prozessdimensionen der Lehrqualität für die Effektivität und Verbesserung der Lehre relevant sein kann (Marsh, 2007). Neben diesen Aspekten wird im SEEQ eine Reihe an Hintergrundvariablen erfasst. Darunter fallen der Aufwand / Anspruch der Veranstaltung (workload / difficulty) sowie Besuchsgrund, Vorleistungen, Erfolgserwartung, Semester und Geschlecht der Studierenden. Von diesen Aspekten wird angenommen, dass sie nicht unmittelbar für die Lehrqualität relevant sind, sich jedoch auf die Studierendeneinschätzungen der Lehrqualität auswirken können (Dresel & Rindermann, 2011). Zuletzt werden spezifische Stärken und Schwächen der evaluierten Veranstaltungen im SEEQ mit einer offenen Frage erfasst.

Der SEEQ wurde für unterschiedliche Länder wie Australien, China, Griechenland, Großbritannien, Indien, Iran, Malaysia, Nigeria, Spanien, Thailand und die Vereinigten Staaten sprachlich adaptiert und überprüft (ESM 1). Es gab bislang jedoch keine überprüfte deutschsprachige Adaption, die sich eng am Originalinstrument orientiert – möglicherweise, da für den deutschsprachigen Raum wie dargestellt andere etablierte Instrumente vorliegen, die ebenfalls auf einem multidimensionalen Verständnis von Lehrqualität fußen (Rindermann, 2009). Um in der Evaluationspraxis die solide theoretische und methodische Basis des SEEQ nutzen zu können und in der Hochschulforschung ein international direkt vergleichbares Instrument bereitzustellen, wird eine deutsche Adaption benötigt, die nah am Original konstruiert ist. Die vorliegende Arbeit berichtet die Konstruktion und Überprüfung einer solchen Adaption. Der Überprüfung liegt die Frage zugrunde, ob die mit dem Instrument er-

hobenen Werte valide interpretiert werden können. Für die intendierte Nutzung als Evaluations- und Forschungsinstrument sind Objektivität und Reliabilität zentrale Voraussetzungen. Während für erstere eine standardisierte Durchführung und Datenerfassung entscheidend sind, gilt es hinsichtlich der Reliabilität insbesondere zwei Aspekte abzusichern (Marsh, 2007): die internen Konsistenzen der Lehrqualitätsdimensionen sowie die Übereinstimmung der Studierendenangaben bei der Beurteilung derselben Lehrveranstaltung. Erst durch ausreichend hohe Reliabilität gemäß dieser beiden Aspekte ist es gerechtfertigt, die einzelnen

Items bzw. die einzelnen Studierendenangaben in Form von Mittelwerten zusammenzufassen, die in der Praxis wiederum als Evaluationsergebnis rückgemeldet werden oder als Grundlage für aufbauende Analysen in der Forschungspraxis dienen. Ohne ausreichend hohe Reliabilität wäre somit keine Nutzung mit dem Instrument gewonnener, aggregierter Werte sinnvoll. Für die valide Interpretierbarkeit der Messergebnisse im Rahmen der angestrebten Nutzung liefern darauf aufbauend folgende Punkte Hinweise:

(1) substanzielle Unterschiede zwischen Lehrveranstaltungen, da Aspekte erfasst werden sollen, hinsichtlich derer sich Lehrveranstaltungen oder Lehrpersonen unterscheiden; sollten sich entsprechende Unterschiede nicht nachweisen lassen, wäre ein Einsatz des Instruments zum Vergleich von Lehrveranstaltungen oder Lehrpersonen nicht angezeigt

(2) die interne Struktur der Qualitätsdimensionen, die sich wie theoretisch angenommen und wie im Originalinstrument voneinander abgrenzen lassen sollte; ohne entsprechende Abgrenzbarkeit wäre es nicht gerechtfertigt, von unterschiedlichen Teilaspekten der Lehrqualität zu sprechen

(3) die Messinvarianz dieser Dimensionen über verschiedene Veranstaltungsformen (Vorlesungen, Seminare, Übungen), da die Items für diese gleichermaßen gut funktionieren sollten; ohne diesen Nachweis wäre es nicht sinnvoll, die Mittelwerte zwischen verschiedenen Veranstaltungsformen zu vergleichen

(4) eine Replikation bekannter mit dem Originalinstrument gewonnener empirischer Befunde etwa in Form von Unterschieden in der Bewertung verschiedener Veranstaltungsformen (Vorlesungen werden durchschnittlich schlechter bewertet als Seminare; Marsh, 2007) sowie positiven Zusammenhängen zwischen Produkt- und Prozessfaktoren (vgl. Marsh, 2007); sollte ein Nachweis entsprechender Befunde ausbleiben, könnte das implizieren, dass der SEEQ-DE anders funktioniert als das Originalinstrument und somit nicht adäquat als deutschsprachige Adaption zu verwenden wäre.

Ein Nachweis dieser Aspekte liefert begründete Hinweise für die valide Interpretation der Testergebnisse gemäß der intendierten Verwendung des Verfahrens als Evaluations- und Forschungsinstrument. Bei der Überprüfung dieser Aspekte ist zu beachten, dass die Studierendenangaben, die unterschiedlichen Veranstaltungen und Dozierenden zuzuordnen sind, auf verschiedenen Ebenen analysiert werden können (Toland & De Ayala, 2005; Sengewald & Vetterlein, 2015). Im Anwendungskontext ist häufig die Veranstaltungsebene naheliegend, da sich Aussagen zur Lehrqualität

unmittelbar auf Lehrveranstaltungen bzw. das Handeln der Lehrpersonen darin beziehen (Marsh, 2007). Gleichwohl ist es ebenfalls wichtig, die Ebene der einzelnen Studierendenangaben zu berücksichtigen. Unabhängig von ihrer Gruppierung in Veranstaltungen, sollten sich Studierendenurteile der Lehrqualität in die unterschiedlichen Faktoren der Lehrqualität differenzieren lassen und die entsprechenden Items sollten diese reliabel abbilden (Marsh, Hau, Chung & Siu, 1998). Reliabilitätsnachweise auf Ebene der Studierenden sind zudem gerade für Forschungszwecke (in denen häufig mehrbenenanalytisch Studierendenurteile als abhängige Variablen betrachtet werden; z. B. Daumiller et al., 2021) eine wichtige Voraussetzung. Für die Überprüfung von faktorieller Struktur und Messinvarianz kann eine simultane Berücksichtigung beider Ebenen mit konfirmatorischen Zwei-Ebenen-Faktorenanalysen (Zwei-Ebenen-CFAs) als besonders geeignet erachtet werden, da diese die hierarchische Datenstruktur berücksichtigen und zudem einen hypothesenprüfenden Ansatz ermöglichen (Sengewald & Vetterlein, 2015). Nachweise der faktoriellen Struktur des SEEQ über diesen mehrbenenanalytischen Zugang stehen trotz einer Vielzahl an Analysen auf einer Ebene noch aus (Toland & De Ayala, 2005). Die jüngste Strukturprüfung führte Marsh et al. (2009) mit Hilfe von Exploratory Structural Equation Modeling (ESEM) Analysen auf Veranstaltungsebene durch (d. h. mit aggregierten Werten). Diese Methode ebenfalls anzuwenden, ermöglicht uns zu prüfen, ob die deutsche Adaption ähnliche Ergebnisse liefert wie von Marsh et al. (2009) berichtet. Zusätzliche Zwei-Ebenen-CFA erlauben darüber hinaus den Forschungsstand zum SEEQ zu erweitern und erhärtende Evidenz bezüglich der faktoriellen Struktur zu liefern.

Adaption des SEEQ

Die Original-Items des SEEQ wurden unter Anwendung einer konsensualen Strategie ins Deutsche übersetzt. In einem mehrstufigen Prozess übersetzten drei der Autoren die Items zunächst unabhängig voneinander und führten die Übersetzungen anschließend zusammen. Zur Absicherung inhaltlicher Nuancen übersetzte sie ein englischsprachiger Muttersprachler zurück ins Englische. Abweichungen zwischen Originalitems und rückübersetzten Items wurden schließlich für nochmalige Anpassungen genutzt. Etwaige Unwägbarkeiten der sprachlichen und kulturellen Anpassung berücksichtigend wurden in der Konstruktionsversion des deutschsprachigen Fragebogens einige Faktoren um zusätzliche Items verlängert und in einer vorangehen-

den Pilotstudie mit Studierendenangaben zu 777 Lehrveranstaltungen getestet. Aufbauend darauf konnten einige der zusätzlichen Items für die endgültige Version der deutschsprachigen Adaption (SEEQ-DE) wieder getilgt werden. Die finalen Items sind in ESM 2 aufgeführt.

Die Subskalen *Lernzuwachs* sowie *Stoffstrukturierung und -präsentation* wurden um jeweils ein Item erweitert. Die Erweiterung der Subskala zum Lernzuwachs liegt darin begründet, dass ein Originalitem zwei inhaltliche Aspekte umfasste (Verständnis und Lernen), die sich im Deutschen nicht adäquat in einem einzigen Item abbilden ließen – sie wurden daher auf zwei Items aufgeteilt (Item 3 und 4). *Stoffstrukturierung und -präsentation* wurde um das Item „Die Inhalte werden gut strukturiert“ erweitert, da durch die deutschsprachige Übersetzung sonst nicht hinreichend sichergestellt wäre, dass das gesamte inhaltliche Spektrum dieses Faktors abgebildet ist.

Das Instrument wurde zudem um zwei inhaltliche Aspekte ergänzt: Zum einen wurde ein weiterer Faktor hinzugenommen, *Studentische Beiträge*, der das Ausmaß misst, zu dem Beiträge von Mitstudierenden ertragreich für das eigene Lernen sind und effektiv durch die Lehrperson gesteuert (d. h. ausgewählt, moderiert und ergänzt) werden. Dies erschien sinnvoll, um einen wesentlichen – aber im SEEQ bislang nicht fokussierten – Aspekt von Lehrformen einzubeziehen, bei denen die Erarbeitung von Inhalten vermehrt interaktiv oder durch Studierendenbeiträge erfolgt, was insbesondere im deutschsprachigen Raum verbreitet ist. Dies mag in Seminaren mit umfangreichen Studierenden-Inputs beispielsweise sehr relevant sein, kann aber auch in interaktiveren Vorlesungen, in denen etwa Studierendenbeiträge aufgegriffen oder kleinere Diskussionen geführt werden, einen informativen Evaluationsaspekt darstellen. Zum anderen betrifft dies eine Erweiterung der *Gesamtbeurteilung* von Lehrveranstaltung und Lehrperson durch zwei Notenurteile. Obwohl davon ausgegangen wird, dass die Gesamtbeurteilung hinreichend messgenau durch die beiden Originalitems erfasst werden kann, schlagen wir die Erweiterung durch Notenurteile vor, da Notenurteile in der Evaluationspraxis von allen Akteursgruppen vielfach als besonders anschaulich eingeschätzt werden (Rindermann, 2009).

Während die zusätzlichen Items zum Lernzuwachs und zur Stoffstrukturierung und -präsentation obligatorisch sind, sind die gegenüber dem SEEQ neuen inhaltlichen Aspekte der Qualität studentischer Beiträge und der Notenurteile zur Gesamtbeurteilung optionale Fragebogenteile. Sie können je nach Evaluationskontext genutzt werden.

Insgesamt umfasst die deutschsprachige Adaption des SEEQ somit zehn Subskalen zur Lehrqualität (vgl. Tabelle 1 für eine Übersicht sowie ESM 2 für alle Items und Antwortformate). Lernzuwachs, Engagement der Lehrperson, Stoffstrukturierung und -präsentation, Aktivierung der Studierenden, Sozialklima, Stoffbreite, Leistungsbewertung und Aufgaben werden mit 2–5 Items auf einer Skala von 1 (*stimme gar nicht zu*) bis 5 (*stimme voll zu*) erfasst. Zusätzlich dazu gibt es die Antwortmöglichkeit *nicht beurteilbar*, die später als fehlender Wert behandelt wird. Dies erlaubt eine einfache Darstellung in der Rückmeldepraxis (z. B. in Form von Mittelwerten) und eine Schätzung des entsprechenden latenten Merkmals in den statistischen Analysen (Holman & Glas, 2005). Die Gesamtbeurteilung wurde mit vier Items auf einer Zensurskala von 1 (*mangelhaft*) bis 5 (*sehr gut*) erfasst. Als Hintergrundvariablen werden wie im Originalinstrument Aufwand bzw. Anspruch der Veranstaltung, Erfolgserwartung, Interesse vor der Veranstaltung, Arbeitsaufwand in Stunden, Vorleistungen, Besuchsgrund, Semester und Geschlecht der Studierenden erfasst. Zudem wird am Ende des Fragebogens eine offene Frage zu spezifischen Stärken und Schwächen der Veranstaltung gestellt.

Ziel der vorliegenden Untersuchung

Das Ziel der vorliegenden Arbeit ist, die Messgüte der deutschsprachigen Adaption des SEEQ zu untersuchen. Die Analysen prüfen die oben dargestellten Aspekte der Reliabilität und Validität, um damit die intendierte Verwendung des Verfahrens als Evaluations- und Forschungsinstrument abzusichern. Im Speziellen wurden zunächst grundlegende Item- und Skaleneigenschaften analysiert. Im Anschluss wurden interne Konsistenzen und die Übereinstimmung der studentischen Urteile in Lehrveranstaltungen bestimmt. Zudem wurden Unterschiede zwischen Lehrveranstaltungen betrachtet sowie die Faktorenstruktur und die Messinvarianz mit ESEM und konfirmatorischen Zwei-Ebenen-Analysen überprüft. Schließlich wurden Unterschiede zwischen verschiedenen Veranstaltungsformen sowie Zusammenhänge zwischen Produkt- und Prozessmerkmalen der Lehrqualität analysiert.

Methode

Stichprobe

Zur Überprüfung des SEEQ-DE wurde eine Stichprobe von 3 660 Lehrveranstaltungen genutzt. Diese fanden zwischen Sommersemester 2013 und Wintersemester 2017/18 an einer mittelgroßen Universität im süddeutschen Raum im gesamten Fachspektrum statt

(davon 2 497 Seminare, 797 Übungen, 105 Vorlesungen und 261 sonstige Veranstaltungen). Insgesamt umfasst die Stichprobe 76 687 Studierendenurteile ($M=21.0$ Urteile pro Veranstaltung, $SD=22.5$; Seminare: $M=16.6$, $SD=9.9$; Übungen: $M=31.0$, $SD=33.5$; Vorlesungen: $M=51.9$, $SD=59.2$; sonstige Veranstaltungen: $M=18.9$, $SD=21.5$). Die beurteilenden Studierenden waren zu 64 % weiblich und durchschnittlich in der Mitte des 3. Semesters ($SD=2.1$).

Prozedur und Einsatz des SEEQ-DE

In der vorliegenden Stichprobe wurde die Lehrveranstaltungsevaluation durchgeführt, indem zunächst Professor_innen auf freiwilliger Basis und in Abstimmung mit ihren Mitarbeiter_innen für den von ihnen verantworteten Bereich die zu evaluierenden Veranstaltungen auswählten. Die Lehrpersonen dieser Veranstaltungen erhielten anschließend eine schriftliche Durchführungsanweisung sowie die Evaluationsbögen (Muster: ESM 3 und ESM 4). Die ausgefüllten Bögen wurden durch Studierende eingesammelt und in einem versiegelten Umschlag an die Qualitätssicherungsstelle der Universität weitergegeben, wo die Daten scanner-gestützt erfasst wurden. Ergänzt durch Interpretationshilfen (Definition der Dimensionen, Vergleichswerte) wurden die Ergebnisse veranstaltungsspezifisch an die einzelnen Dozierenden rückgemeldet.

Die deutschsprachige Adaption des SEEQ wurde in der oben beschriebenen Form eingesetzt, einschließlich der optionalen Items. Die Professor_innen entschieden je nach Konzeption der Vorlesungen in ihrem Bereich, ob darin die zusätzliche Skala *studentische Beiträge* mit eingesetzt wurde oder nicht (in 53 % der Vorlesungen wurde diese eingesetzt). Der Bogen wurde – wie in der Durchführungsanweisung empfohlen – überwiegend zu Beginn einer Sitzung etwa in der Mitte des Semesters eingesetzt. Die dafür erforderliche Zeit betrug etwa 5–10 Minuten.

Ergebnisse

Grundlegende Skaleneigenschaften

Alle Subskalen der Lehrqualität nahmen auf Studierendenebene das gesamte Spektrum möglicher Werte an (vgl. Tabelle 1). Zudem waren bei allen Subskalen sowohl auf Studierenden- als auch auf Veranstaltungsebene nennenswerte Varianzen bzw. Standardabweichungen beobachtbar, was auf substantielle Unterschiede zwischen Urteilenden und Veranstaltungen schließen lässt. Die Unterschiede zwischen den Studierenden waren dabei deskriptiv etwas größer als die Unterschiede auf Veranstaltungsebene (was auch zu erwarten ist, da die Varianz auf Studierendenebene neben

Tabelle 1. Deskriptive Statistiken

	Items ^a	Studierendenebene (N = 76 687)										Veranstaltungsebene (N = 3 660)								
		M	SD	Range	Schiefe	Kurtosis	r _{it}	ω _h	α	ICC1	ICC2	M	SD	Range	Schiefe	Kurtosis	r _{it}	ω _h	α	
Lehrqualität																				
Lernzuwachs	4/5	3.9	0.8	1.0–5.0	–0.6	0.2	.47–.71	.78	.84	.40	.90	4.0	0.4	2.2–5.0	–0.3	–0.1	.54–.86	.88	.91	
Gesamtbeurteilung	2/4	4.0	0.8	1.0–5.0	–0.9	0.7	.80–.83	.86	.92	.47	.92	4.2	0.5	2.1–5.0	–0.8	0.7	.92–.93	.93	.97	
Engagement der Lehrperson	4/4	3.9	0.9	1.0–5.0	–0.9	0.5	.71–.71	.85	.88	.50	.93	4.1	0.5	1.7–5.0	–0.7	0.4	.82–.91	.92	.93	
Stoffstrukturierung und -präsentation	4/5	4.1	0.7	1.0–5.0	–0.9	1.2	.52–.70	.77	.82	.24	.84	4.2	0.3	2.5–5.0	–0.7	1.2	.53–.84	.84	.87	
Aktivierung der Studierenden	4/4	4.2	0.8	1.0–5.0	–1.1	1.2	.77–.91	.87	.92	.34	.91	4.4	0.4	2.0–5.0	–1.0	1.3	.84–.93	.89	.95	
Sozialklima	4/4	4.3	0.7	1.0–5.0	–1.2	1.8	.59–.81	.85	.87	.22	.85	4.4	0.5	2.6–5.0	–0.9	1.4	.68–.90	.89	.90	
Stoffbreite	4/4	3.8	0.8	1.0–5.0	–0.6	0.3	.63–.73	.83	.85	.26	.86	4.0	0.4	2.1–5.0	–0.4	0.2	.67–.82	.89	.88	
Leistungsbewertung	3/3	4.1	0.8	1.0–5.0	–1.0	1.1	.65–.74	.85	.85	.19	.79	4.2	0.4	2.3–5.0	–0.6	0.7	.63–.76	.84	.84	
Aufgaben	2/2	4.0	0.9	1.0–5.0	–0.9	0.8	.71–.71	.83	.83	.15	.70	4.1	0.4	2.0–5.0	–0.5	1.0	.67–.67	.80	.80	
Studentische Beiträge	–/4	3.9	0.8	1.0–5.0	–1.0	1.4	.57–.68	.76	.81	.30	.85	4.0	0.4	2.0–5.0	–0.7	0.7	.71–.81	.82	.82	
Hintergrundvariablen ^b																				
Aufwand/Anspruch der Veranstaltung	3/3	3.5	0.7	1.0–5.0	–0.2	0.1	.57–.67	.79	.78	.45	.90	3.5	0.4	1.9–5.0	–0.1	–0.1	.73–.82	.88	.86	
Erfolgserwartung der Studierenden	1/1	3.6	0.8	1.0–5.0	–0.4	0.3				.19		3.7	0.4	2.3–5.0	–0.1	0.5				
Interesse vor Veranstaltung	1/1	3.4	1.1	1.0–5.0	–0.4	–0.4				.20		3.5	0.5	1.5–5.0	–0.3	0.1				
Arbeitsaufwand in Stunden	1/1	3.2	1.3	1.0–6.0	0.5	–0.5				.42		3.3	1.0	1.0–6.0	0.8	0.3				
Vorleistungen der Studierenden	1/1	2.3	0.6	1.0–5.0	0.4	0.7				.16		2.2	0.3	1.0–4.0	0.2	0.5				
Semester der Studierenden	1/1	2.1	1.1	1.0–6.0	0.9	0.5				.59		2.2	0.9	1.0–5.6	0.4	–0.5				
Geschlecht der Studierenden ^c	1/1	0.64		0.0–1.0						.17		0.7	0.2	0.0–1.0	–0.4	–0.6				

Anmerkungen: ^a Itemanzahl im Original SEEQ / in der deutschen Adaption. Reliabilitäten bezogen auf alle Items. ^b Der „Besuchsgrund der Studierenden“ (polytomes Item auf

Nominalskalenniveau): 40 % Pflicht, 27 % Wahlpflicht, 1 % Termin, 17 % Interesse, 14 % Prüfungsvorbereitung. ^c 0 = männlich, 1 = weiblich.

Veranstaltungsunterschieden auch Nicht-Übereinstimmungen zwischen Studierenden derselben Veranstaltungen reflektiert). Obwohl durchgehend Mittelwerte oberhalb der theoretischen Skalenmitte von 3.0 beobachtet wurden, indizierten die Werteverteilungen sowie Schiefe und Kurtosis (die stets innerhalb der gebräuchlichen Grenzen von $+/-2$ lagen; Gravetter & Wallnau, 2014) keine Verletzung der Normalverteilung auf beiden Ebenen, was eine wichtige Voraussetzung für die nachfolgenden Analysen ist.

Interne Konsistenzen

Zur Bestimmung der internen Konsistenzen wurde McDonald's Omega (ω_h) berechnet (Dunn, Baguley & Brunsden, 2014). Zur Vergleichbarkeit mit älteren Studien zum SEEQ berichten wir zudem Cronbach's α . Alle internen Konsistenzen der Subskalen lagen in einem guten bis sehr guten Bereich (vgl. Tabelle 1). Dies ist eine entscheidende Bedingung für eine messgenaue Einschätzung einzelner Lehrveranstaltungen. Auch die Subskala zur Gesamtbeurteilung ohne die zwei zusätzlichen Items lieferte gute Kennwerte ($\omega_h = .82$ auf Studierenden- und $\omega_h = .92$ auf Veranstaltungsebene).

Urteilerübereinstimmung

Für eine reliable Erfassung von Veranstaltungsmerkmalen mit Hilfe studentischer Urteile ist es ferner nötig, dass die Studierenden innerhalb von Lehrveranstaltungen in hinreichendem Maße in ihren Einschätzungen übereinstimmen. Hierbei ist zu berücksichtigen, dass kein einheitlicher Effekt des Lehrhandelns von Dozierenden auf die einzelnen Studierenden erwartet werden kann (z. B. differenzielle Lerneffekte aufgrund heterogener Voraussetzungen), sodass perfekte Urteilerübereinstimmung nicht realistisch ist. Die Übereinstimmung wird durch die Intraklassenkorrelation ICC2 quantifiziert, die wie herkömmliche Reliabilitätskoeffizienten interpretiert werden kann (Lüdtke, Robitzsch, Trautwein & Kunter, 2009). Werte nahe 1 geben an, dass Studierende in denselben Veranstaltungen sehr ähnliche Einschätzungen abgeben. Die ICC2 Werte (vgl. Tabelle 1) lagen bei allen Subskalen in einem zufriedenstellenden bis sehr guten Bereich.

Darauf aufbauend kann bestimmt werden, wie viele Studierendenurteile nötig sind, um auch für jede Einzelveranstaltung eine hinreichende Reliabilität der Einschätzungen zu erhalten (Lüdtke et al., 2009). Wird dafür $ICC2 \geq .60$ angesetzt, erhält man für die Subskala mit dem geringsten Varianzanteil auf Veranstaltungsebene (Aufgaben, $ICC1 = .15$), dass dafür mindestens 8.5 Urteile vorliegen sollten. Daraus folgt, dass eine

Lehrveranstaltung von mindestens 9 Studierenden beurteilt werden sollte, um bei allen Subskalen eine hinreichende Zuverlässigkeit der auf die einzelne Lehrveranstaltung bezogenen Ergebnisse zu gewährleisten.

Unterschiede zwischen Lehrveranstaltungen

Eine basale Voraussetzung für eine valide Interpretation der erfassten Aspekte der Lehrqualität ist, dass sich Lehrveranstaltungen bzw. Lehrpersonen bezüglich dieser Aspekte unterscheiden. Dementsprechend sollte eine hinreichende Varianz zwischen Veranstaltungen vorliegen. Ohne eine solche wäre eine Messung aus Gründen der Ökonomie sowie aus der damit implizierten nicht gegebenen Veränderbarkeit auch wenig sinnvoll.

Der Anteil der Zwischenveranstaltungsvarianz an der Gesamtvarianz wird durch die Intraklassenkorrelation ICC1 quantifiziert, wobei Werte von $ICC1 = .05$ als kleine und Werte von $ICC1 = .20$ als große Unterschiede zwischen Kursen interpretiert werden können (Snijders & Bosker, 2020). Bei allen Subskalen des SEEQ-DE waren moderate bis sehr große Unterschiede zwischen Lehrveranstaltungen zu verzeichnen, vor allem beim Lernzuwachs, bei der Gesamtbeurteilung und beim Engagement der Lehrperson (vgl. Tabelle 1).

Faktorielle Struktur

Zur Untersuchung der internen Struktur verwendeten wir zunächst ESEM-Analysen mit Geomin Rotation auf Veranstaltungsebene analog zu Marsh et al. (2009), um zu prüfen, ob der SEEQ-DE ähnliche Ergebnisse liefert. Zudem führten wir konfirmatorische Zwei-Ebenen-Analysen durch, die im vorliegenden Fall besonders angemessen sind (Sengewald & Vetterlein, 2015).¹ Wie bei Marsh et al. (2009) ließen wir Ladungen der beiden Items zur Gesamtbewertung der Lehrveranstaltung auf die Dimension *Lernzuwachs* sowie Ladungen der beiden Items zur Gesamtbewertung der Lehrperson auf die Dimension *Engagement der Lehrperson* zu. Die Analysen wurden mit Mplus 8.1 (Muthén & Muthén, 2017) durchgeführt. Fehlende Werte wurden modellbasiert mittels FIML-Schätzer und EM-Algorithmus geschätzt (Peugh & Enders, 2004). Zur Evaluation der Modellfits wurden den Vorschlägen von Kline (2015) folgend χ^2 , CFI, TLI, RMSEA und SRMR als Fit-Indizes herangezogen. Hierbei ist zu berücksichtigen, dass gerade bei umfangreichen und komplexen Messmodellen (d. h. mit vielen Items und Faktoren) eher liberale Cut-Off-Werte verwendet werden sollten, da es hierbei unwahrscheinlich ist, strenge Kriterien zu erreichen (Cheung & Rensvold,

¹ Zusätzlich führten wir konfirmatorische Faktorenanalysen auch ausschließlich auf Studierendenebene durch. Die Resultate waren sehr ähnlich zu den hier berichteten Ergebnissen.

2002; Fan & Sivo, 2007). Als Indikatoren für einen akzeptablen Modellfit verwendeten wir daher $CFI \geq .90$ und $TLI \geq .90$ (Byrne, 2013) sowie $RMSEA \leq .08$ und $SRMR \leq .10$ (Schermelleh-Engel, Moosbrugger & Müller, 2003). Zudem ist zu berücksichtigen, dass gegeben der Neuheit der ESEM-Analysen zu diesem Zeitpunkt keine abweichenden Empfehlungen zur Beurteilung der Güte der damit geschätzten Modelle vorliegen.

Die ESEM-Ergebnisse (ESM 5) waren sehr ähnlich zu den von Marsh et al. (2009) für den Original-SEEQ berichteten und indizierten einen zufriedenstellenden Fit zu den Daten. Die Faktorladungen (vgl. ESM 6) bestätigten die 10-faktorielle Struktur und waren vergleichbar mit den Ladungsmustern bei Marsh et al. (2009) sowie den für explorative Faktorenanalysen typischerweise berichteten Ergebnissen (Marsh, 2007). Bemerkenswert ist, dass die höheren Querladungen der Items zur Gesamtbeurteilung genau mit den Ergebnissen von Marsh et al. (2009) korrespondieren (auf die Lehrveranstaltung bezogene Items laden auch auf den Faktor *Lernzuwachs*; auf die Lehrperson bezogene Items laden indes stärker auf den Faktor *Engagement*).

Die Zwei-Ebenen-CFA (ESM 5) erbrachte ebenfalls einen akzeptablen Modellfit. Angesichts der Modellkomplexität und der teils substanziellen Querladungen in den ESEM-Analysen, die für diese Analyse auf null gesetzt wurden, ist es nicht verwunderlich, dass die erreichten Fit-Indizes nicht besser ausfielen.

Bei beiden Analysen zeigte sich, dass die Zusatzitems zur Gesamtbeurteilung auf dem gleichen Faktor wie die beiden etablierten Items luden und dass die optionale Dimension *studentische Beiträge* auch empirisch einen separaten Faktor darstellte.² Da die Subskala *studentische Beiträge* nur in etwa der Hälfte der evaluierten Vorlesungen eingesetzt wurde und um die Vergleichbarkeit zu den Analysen des Originalinstruments zu erhöhen, führten wir zusätzlich analoge Analysen ohne diese Subskala durch. Die Ergebnisse unterschieden sich nicht substanziell von den hier berichteten Resultaten und werden im Detail in ESM 7 und ESM 8 berichtet.

Zusammenfassend sprechen die faktorenanalytischen Befunde dafür, dass mit dem adaptierten Instrument die multifaktorielle Lehrqualität gemäß der international etablierten und für die deutsche Adaption postulierten Struktur erfasst werden kann.

Messinvarianz für unterschiedliche Veranstaltungsformen

Darauf aufbauend ist es ferner wichtig, dass diese Faktorenstruktur über verschiedene Veranstaltungsformen hinweg besteht und die Items der einzelnen Faktoren dasselbe messen (Fondel, Lischetzke, Weis & Gollwitzer, 2015). Deshalb betrachten wir die Messinvarianz des Instruments über Übungen, Seminare und Vorlesungen hinweg. Diese Analysen führten wir basierend auf den Zwei-Ebenen-CFAs durch, da in diesen die genestete Datenstruktur am passendsten berücksichtigt wird.³ Dazu wurden mehrere zunehmend restriktive Multi-Gruppen-Modelle geschätzt (Muthén & Muthén, 2017). Zunächst wurde eine äquivalente Struktur der Faktorladungsmatrix über die drei Gruppen hinweg modelliert (*konfigurale Messinvarianz*). Anschließend wurden zusätzlich die Faktorladungen zwischen den Gruppen gleichgesetzt (*metrische Messinvarianz*). Schließlich wurden noch die Intercepts der Indikatoren zwischen den Gruppen restringiert (*skalare Messinvarianz*). Unterschiede im Modellfit evaluierten wir durch Betrachtung der Unterschiede in den CFI- und RMSEA-Werten (unter Verwendung der empfohlenen Cut-Off Werte von: $\Delta CFI = .01$, $\Delta RMSEA = .015$, $\Delta SRMR = .03$ für metrische und $\Delta SRMR = .01$ für skalare Messinvarianz; vgl. Chen, 2007). Angesichts der großen Stichprobe sind diese Werte χ^2 -Tests vorzuziehen und dabei wiederum vor allem die ΔCFI Werte relevant, da $\Delta RMSEA$ und $\Delta SRMR$ negativ mit der Güte des Gesamtmodellfits assoziiert sind, d. h. bei schlechterem Gesamtmodellfit automatisch größer werden, sodass weniger restriktive Cut-Off-Werte angelegt werden müssten (Cheung & Rensvold, 2002).

Die Ergebnisse (vgl. ESM 5) zeigten, dass die restriktiveren Modelle die Daten nur unwesentlich schlechter beschrieben als die vorangehenden Modelle (insbesondere hinsichtlich CFI, aber auch hinsichtlich RMSEA und SRMR). Dies indiziert skalare Messinvarianz für die verschiedenen Veranstaltungsformen und erlaubt es somit, die manifesten und latenten Mittelwerte der Lehrqualitätsdimensionen zwischen Veranstaltungen verschiedenen Typus zu vergleichen.

² Interessanterweise fielen die Ladungen der Items 1 (passende Themen) und 4 (sinnvolle Ergänzungen), die stärker das Verhalten der Lehrperson als jenes der Kommiliton_innen beurteilen, niedriger aus als die anderen beiden Items. Eine zusätzlich durchgeführte explorative Faktorenanalyse lieferte jedoch keine Hinweise darauf, dass die 4 Items mehr als einen Faktor bilden.

³ Zur Absicherung führten wir die Analysen ebenfalls auf Basis des ESEM-Modells durch. Diese Analysen erbrachten zur Messinvarianz gleiche Resultate wie die Analysen auf Basis der Zwei-Ebenen-CFAs.

Unterschiede in der Beurteilung verschiedener Veranstaltungsformen

Basierend darauf wurde überprüft, ob das Instrument in der Lage ist, die gut dokumentierten Niveauunterschiede bei der Beurteilung von unterschiedlichen Formen von Veranstaltungen abzubilden, insbesondere jene zwischen Vorlesungen und Seminaren (Rindermann, 2009). Dazu führten wir auf Veranstaltungsebene eine MANOVA mit nachfolgenden Bonferroni-Post-Hoc Vergleichen durch.⁴ Darin betrachteten wir die Lehrqualitätsdimensionen als abhängige Variablen und die Veranstaltungsform als dreistufigen Faktor. Wir fanden große, statistisch signifikante Unterschiede zwischen den drei Veranstaltungsformen (Wilks $\eta^2 = .684$; *multivariate* $F(20, 6706) = 70.04$; $p < .001$; $\eta^2 = .17$), die in ESM 8 dargestellt sind. Vorlesungen wurden hinsichtlich aller Faktoren durchschnittlich signifikant schlechter eingestuft als Seminare. Zusätzliche Validitätshinweise lieferte das Profil der Mittelwertdifferenzen, das erwartungsgemäß bei der Aktivierung von Studierenden und studentischen Beiträgen (eher schwer in Vorlesungen umfassend zu realisierende Aspekte) besonders große und beim Engagement der Lehrperson, der Stoffstrukturierung und -präsentation sowie der Aufgaben (veranstaltungsformunabhängig relevante Aspekte) eher kleinere Unterschiede aufwies. Ferner wurden Übungen im Durchschnitt schlechter bewertet als Seminare, was möglicherweise auf die geringere didaktische Erfahrung der Tutor_innen, die in der Regel selbst Studierende sind, zurückgeführt werden kann.

Beziehungen der Prozessmerkmale des Lehrhandelns mit Lernzuwachs und Gesamtbeurteilung

Zur weiteren Prüfung bekannter empirische Befunde zum Originalinstrument wurden auf Grundlage des 10-faktoriellen Modells Korrelationen zwischen den beiden Produktfaktoren des Lehrerfolgs (*Lernzuwachs*, *Gesamtbeurteilung*) mit den acht Prozessfaktoren des Lehrhandelns bestimmt. Dem lag die Annahme zugrunde, dass ein gültiges Instrument zur Beurteilung der Lehrqualität Lehrdimensionen erfassen muss, die für den Lernzuwachs der Studierenden und deren Gesamtbeurteilung der Lehrveranstaltungen von Relevanz sind. Im Einklang mit Befunden zum Originalinstrument (vgl. Marsh, 2007) erwarteten wir positive Zusammenhänge zwischen den Prozess- und den Produktmerkmalen der Lehrqualität. Dies war durchgehend der

Fall: Für alle acht im SEEQ-DE einbezogenen Prozessfaktoren des Lehrhandelns waren auf Veranstaltungsebene substanzielle Zusammenhänge mit beiden Lehrerfolgsindikatoren zu beobachten, die indizierten, dass eine stärkere Ausprägung des jeweiligen Lehrhandlungsfaktors mit Bewertungen eines insgesamt größeren Lehrerfolgs einherging (Korrelationen auf Grundlage des ESEM Modells für Engagement: $\rho = .37$ mit dem Lernzuwachs / $\rho = .58$ mit der Gesamtbeurteilung; Stoffstrukturierung und -präsentation: $\rho = .32 / .40$; Aktivierung der Studierenden: $\rho = .25 / .33$; Sozialklima: $\rho = .23 / .48$; Stoffbreite: $\rho = .32 / .33$; Leistungsbewertung: $\rho = .32 / .05$; Aufgaben: $\rho = .38 / .35$; studentische Beiträge: $\rho = .41 / .18$). Die Höhe dieser Korrelationen war deskriptiv sehr ähnlich zu den bei Marsh et al. (2009) berichteten (alle $|\Delta\rho| \leq .13$).⁵ Wurde die Gesamtbeurteilung ohne die beiden optionalen Items berechnet, fanden sich nahezu identische Korrelationen. Regressionsanalysen verwiesen auf einen inkrementellen Erklärungswert durch den zusätzlichen Faktor *studentische Beiträge*, der auch unter Kontrolle der anderen Prozessfaktoren einen statistisch signifikanten Effekt auf den Lernzuwachs ($\beta = .27$, $p < .001$) sowie die Gesamtbeurteilung ($\beta = .05$, $p = .001$) hatte.

Weiterführende Analysen erbrachten, dass diese Zusammenhänge in allen Veranstaltungsformen vorlagen – für die Korrelationen zeigten sich zwischen den drei Veranstaltungsformen keine nennenswerten Unterschiede. Dies ist ein Hinweis darauf, dass die einbezogenen Prozessfaktoren in Übereinstimmung mit der Forschungsliteratur (Marsh, 2007) von globaler Relevanz für alle Veranstaltungsformen und nicht nur für bestimmte Formen von Lehrveranstaltungen bedeutsam sind.

Diskussion

Ziel der vorliegenden Untersuchung war die Konstruktion und Überprüfung einer deutschsprachigen Adaption des Fragebogens „Student Evaluation of Educational Quality“ von Marsh (1982, 2007). Dazu wurde das Inventar im Rahmen einer separaten Pilotierungsstudie übersetzt und geringfügig erweitert sowie anhand eines umfangreichen Datensatzes umfassend untersucht. Da der SEEQ zwar für viele Sprachen, aber noch nicht für den deutschsprachigen Raum, adaptiert wurde, wird mit der vorliegenden Arbeit eine Lücke geschlossen und ein Instrument zur Verfügung gestellt,

⁴ Zur Absicherung dieser Resultate setzten wir zudem im Modell der skalaren Messinvarianz der zehn Lehrqualitätsdimensionen gleich und fanden im Einklang zu den manifesten Analysen eine statistisch signifikante Verschlechterung des Modellfits. ⁵ Da in den ESEM Analysen bei Marsh et al.

(2009) keine Ergebnisse zur Gesamtbeurteilung berichtet wurden, wurden nur die Korrelationen mit dem Lernzuwachs verglichen.

das auf äußerst umfangreichen Validierungsbelegen fußt, die auf internationaler Ebene gewonnenen wurden. Es ergänzt die im deutschsprachigen Raum weit verbreiteten multifaktoriellen Instrumente zur Erfassung der Lehrqualität, die oft hohe Standards der Messgüte erfüllen und im Praxiseinsatz als bewährt gelten. Der SEEQ-DE ist neben der Evaluation einzelner Lehrveranstaltungen insbesondere auch auf die Hochschulforschung ausgelegt, um die Anschlussfähigkeit an die internationale Forschungsliteratur, insbesondere jener zum SEEQ, zu gewährleisten. Um begründete Schlussfolgerungen zur Validität der Interpretation der Testergebnisse gemäß der intendierten Verwendung als Evaluations- und Forschungsinstrument zu erlangen, wurden zentrale Aspekte der Messgüte aufgegriffen und empirisch geprüft (interne Konsistenz, Urteilerübereinstimmung, Unterschiede zwischen Lehrveranstaltungen, interne Struktur der Lehrqualitätsdimensionen und deren Messinvarianz, Replikation bekannter Befunde). Die Stärken der berichteten Analysen liegen in der umfassenden Datengrundlage sowie den Berechnungen unter Berücksichtigung der Studierenden- und Veranstaltungsebene. Zusammenfassend erbrachten die durchgeführten Analysen klare Hinweise auf eine zulässige Nutzung des Messinstruments als Evaluations- und Forschungsinstrument.

In Bezug auf die Objektivität kann zunächst festgehalten werden, dass Durchführungs- und Auswertungsobjektivität aufgrund der standardisierten Testdurchführung (schriftliche Instruktion, exakte Durchführungsvorgaben) und Datenerfassung (im Workflow der universitären Qualitätssicherung typischerweise maschinell) als sehr hoch angenommen werden können. Die Interpretationsobjektivität kann durch Vergleichswerte aus anderen Veranstaltungen unterstützt werden (wobei Normwerte auf Basis einer repräsentativen Veranstaltungsstichprobe bislang allerdings nicht zur Verfügung stehen). In Anbetracht der aufgezeigten Unterschiede zwischen unterschiedlichen Veranstaltungsformen sollten hierfür spezifische Vergleichswerte genutzt werden (Vetterlein & Sengewald, 2015). Zur Erweiterung des Lernpotentials von Evaluationsrückmeldungen ist ferner eine persönliche Rückmeldung denkbar, mit der die einzelnen Dozierenden den Verlauf ihrer Lehrqualität über die Zeit betrachten können (Marsh, 2007). Unabhängig vom Verwendungszweck und der angelegten Bezugsnorm erlaubt das Verfahren eine Korrektur der Evaluationsergebnisse für Bias- und Unfairnesseffekte mit Hilfe der erfassten Hintergrundvariablen, um die Angemessenheit der Ergebnisse und deren sachgemäße Interpretation zusätzlich zu verbessern (Staufenbiel, Seppelfricke & Rickers, 2016). Eine

solche Korrektur – beispielsweise in Form der Berücksichtigung dieser Variablen als Kontrollvariablen – ist insbesondere in Forschungskontexten oftmals unumgänglich, um zu validen Aussagen über inter- und intraindividuelle Unterschiede in der Lehrqualität zu gelangen (z. B. Dresel & Rindermann, 2011). In der Evaluationspraxis kann schließlich die Akzeptanz der Evaluationsrückmeldungen durch eine inhaltliche Beschreibung der erfassten Lehrqualitätsdimensionen unterstützt werden (ESM 9).

Die Analyse der grundlegenden Skaleneigenschaften erbrachte, dass ein großes Wertespektrum angenommen wurde und deutliche Unterschiede insbesondere zwischen Veranstaltungen bestanden, aber auch innerhalb von Veranstaltungen zwischen den Urteilen der einzelnen Studierenden. Dabei fand sich das für Lehrqualitätseinschätzungen durch Studierende typische und auch für den SEEQ bekannte Muster, dass die Bewertungen im Schnitt deutlich über dem theoretischen Skalenmittelwert lagen (Marsh, 1982).

Im Hinblick auf die Reliabilität erbrachten die Analysen durchgehend sehr zufriedenstellende Kennwerte. Erstens zeigte sich, dass die verschiedenen Items die jeweiligen Faktoren hinreichend intern konsistent messen und die entsprechenden Reliabilitätskennwerte ähnlich zu jenen sind, die für den Original-SEEQ berichtet wurden (vgl. Marsh, 2007). Dass die auf Veranstaltungsebene guten bis sehr guten internen Konsistenzen auf Studierendenebene tendenziell etwas weniger hoch ausfielen (aber mit $\omega_h = .76\text{--}.87$ immer noch sehr zufriedenstellend), spricht gegen Antworttendenzen oder undifferenziertes Antwortverhalten. Eine Sichtkontrolle einer Teilstichprobe von 150 Fragebögen bestärkt dies, da in diesen nur sehr selten konsistente Antwortmuster vorzufinden waren. Zweitens verwiesen die hohen Intraklassenkorrelationen ICC2 darauf, dass Studierende derselben Veranstaltungen zu hinreichend ähnlichen Einschätzungen kommen, so dass messgenau auf die einzelnen Lehrqualitätsdimensionen als Veranstaltungsmerkmale geschlossen werden kann. Zu betonen ist, dass aus den Ergebnissen selbst für ein in dieser Hinsicht reliables Verfahren für die Evaluationspraxis folgt, dass in jeder zu bewertenden Veranstaltung eine relativ große Mindestanzahl von Studierendenurteilen (hier: neun) vorliegen muss, um hinreichend präzise Einzelergebnisse zu erhalten. Mit weniger Studierenden sollte eine Lehrveranstaltungsevaluation – auch aus Gründen der Anonymität der Studierenden – eher nicht durchgeführt werden. Zudem sollte berücksichtigt werden, dass Unterschiede zwischen den Urteilen der Studierenden auch ein wichtiges Feedback für die Dozierenden darstellen, da diese eine differenziell

wirksame Lehre ausdrücken können. Daher bietet sich zusätzlich zu den Mittelwerten eine Rückmeldung des gesamten Wertespektrums der Studierendenurteile an.

Für die valide Interpretation der mit dem SEEQ-DE erfassten Lehrqualität spricht in Analogie zum Originalinstrument zunächst, dass sich die inkludierten Faktoren aus theoretischen Annahmen zur Effektivität von Instruktion ableiten (u. a. Berücksichtigung von Prozess- wie Produktmerkmalen; Döring, 2005; Rindermann, 2009) sowie in Korrespondenz zu übergreifenden Prinzipien des Lehrens und Lernens in Hochschulen stehen (z. B. Feldman, 1976; Fincher, 1985). Darüber hinaus belegt eine große Zahl an empirischen Studien in unterschiedlichen instruktionalen und kulturellen Kontexten die Relevanz dieser Faktoren für den Lernertrag der Studierenden (Perry & Smart, 2007; Spoor et al., 2013). Insbesondere werden die Items des Originalinstruments in der Forschung zur Effektivität von Hochschullehre seit vielen Jahren als inhaltsgültig für die jeweiligen Faktoren der Lehrqualität betrachtet (Marsh, 2007). Beide Aspekte – solide theoretische Fundierung und umfassende empirische Evidenz – verweisen auf eine umfassende inhaltliche Abdeckung des zu messenden Konstrukts, die entsprechend auch in der deutschsprachigen Adaption anzunehmen ist (aufgrund der Inhaltsgleichheit und der prinzipiellen Vergleichbarkeit der Qualitätsaspekte universitärer Lehre in unterschiedlichen Hochschulkontexten und Ländern).

Die weiterführenden Analysen der deutschsprachigen Adaption bestätigten die Unterscheidung in die verschiedenen Prozess- und Produktfaktoren der Lehrqualität: Auf Ebene der Lehrveranstaltungen und unter Berücksichtigung der geschachtelten Datenstruktur ließen sich in Faktorenanalysen die zehn erfassten Faktoren klar voneinander trennen. Dies untermauert die Annahme einer multifaktoriellen Lehrqualität, die die postulierten Prozessfaktoren des Lehrhandelns und Produktfaktoren des Lehrerfolgs umfasst (Marsh & Roche, 1997). Dies gilt ebenso für den im SEEQ-DE zusätzlich aufgenommenen Faktor *studentische Beiträge*. Zu betonen ist, dass zwei unterschiedliche Analyseverfahren zur Prüfung der faktoriellen Struktur verwendet wurden. Die zum Vergleich mit den aktuellsten zur Struktur des SEEQ vorgelegten Befunden durchgeführten ESEM-Analysen erbrachten ähnliche Ergebnisse wie für das Originalinstrument (Marsh et al., 2009). Die Zwei-Ebenen-CFAs erlaubten es, das hierarchische Design von Lehrveranstaltungsevaluationen abzubilden (Sengewald & Vetterlein, 2015), und lieferten durch Replikation der faktoriellen Abgrenzbarkeit der verschiede-

nen Lehrqualitätsaspekte unter simultaner Berücksichtigung der Studierenden- und Dozierendenebene erhärtete Evidenz zu ihrer faktoriellen Struktur. Die unseres Wissens erstmalige konfirmatorische Bestätigung der Faktorenstruktur des SEEQ durch Zwei-Ebenen-Analysen erweitert den Forschungsstand zu dessen Struktur auch methodisch. Einen weiteren Beleg für die valide Interpretierbarkeit der mit dem SEEQ-DE erfassten Aspekte der Lehrqualität besteht darin, dass die theoretisch erwartete Faktorenstruktur in Übungen, Seminaren und Vorlesungen gleichermaßen gegeben ist. Dies impliziert die Generalisierbarkeit dieser Faktoren über unterschiedliche Veranstaltungsformen hinweg und ist eine wichtige Voraussetzung für die Ergebnisinterpretation: Auf Basis der gezeigten skalaren Messinvarianz können die Ergebnisse unterschiedlicher Veranstaltungen sinnvoll miteinander verglichen werden. Zwei weitere Validitätsbelege lieferte die Replikation von Befunden, die mit dem Originalinstrument gewonnen wurden. Die teils erheblichen Unterschiede zwischen den durchschnittlichen Lehrqualitätsbeurteilungen von Vorlesungen, Seminaren und Übungen fielen analog zu den bisherigen Ergebnissen in der Literatur aus (z. B. Rindermann, 2009). Zudem fanden wir theoriekonforme und in der Höhe vom Original-SEEQ bekannte Interkorrelationen zwischen den erfassten Prozessmerkmalen der Lehre sowie dem Lernzuwachs der Studierenden und deren Gesamtbeurteilung der Veranstaltungen (Marsh, 2007). Trotz dieser Belege ist als Einschränkung der vorliegenden Arbeit anzuführen, dass keine externen Merkmale wie Leistungs- oder Beobachtungsdaten berücksichtigt werden konnten. Gerade die Analyse von Zusammenhängen mit objektiven Leistungsdaten ist eine wichtige Perspektive für zukünftige Forschungsarbeiten (Stehle, Spinath & Kadmon, 2012). Darüber hinaus läge ein zukünftiger Validierungsschritt auch in der parallelen Darbietung des SEEQ-DE und des englischsprachigen Originals in einer Stichprobe von Studierenden, die beide Sprachen ausreichend beherrschen. Der SEEQ ist ein ökonomisches und transparentes Verfahren, das als besonders fair gilt; es ist von Studierenden wie Dozierenden akzeptiert und wird von ihnen vielfach als hilfreich eingestuft (Marsh, 2007). Die in der deutschen Adaption des SEEQ zusätzlich aufgenommenen Aspekte (Gesamtbeurteilung in Form von Noten, Subskala zu studentischen Beiträgen), die anlassbezogen optional eingesetzt werden können, tragen zusätzlich zur Nützlichkeit des Verfahrens bei. Abseits der Konstruktion und Überprüfung des SEEQ-DE liefern die präsentierten Resultate einen zusätzlichen Beitrag zur Generalisier-

barkeit der Dimensionen von Lehrqualität über verschiedene Kontexte hinweg und fügen sich damit in eine Reihe internationaler Arbeiten dazu ein (vgl. ESM 1). Darüber hinaus stehen die Befunde im Einklang mit der Forderung, dass unterschiedliche Dimensionen der Lehrqualität bei Studierendenevaluationen der Lehre berücksichtigt werden sollten (Spooren et al., 2013), und sie bestätigen, dass diese über verschiedene Veranstaltungsformen hinweg ähnlich strukturiert sind (Marsh et al., 2009). Von hohem praktischem Wert ist ferner, dass sich die im Messinstrument enthaltenen Dimensionen des Lehrhandelns unabhängig von der Veranstaltungsform als relevant für den Lehrerfolg erwiesen. Dies spricht dafür, dass die unterschiedenen Lehrqualitätsdimensionen für alle Veranstaltungsformen von praktischer Relevanz sind und für die Verbesserung der Lehre berücksichtigt werden sollten. Trotz der genannten Stärken der vorliegenden Untersuchung sind bei der Interpretation der Ergebnisse wichtige Limitationen zu berücksichtigen. Zunächst ist zu bedenken, dass die vorliegenden Befunde auf einer papierbasierter Durchführung der Lehrveranstaltungsevaluationen beruhen (siehe Janke et al., 2020, für eine elektronische Umsetzung). Zwar ist von einer ähnlichen Güte bei einer Online-Befragung auszugehen, jedoch könnte es Unterschiede vor allem in der Teilnahmebereitschaft, aber in gewissem Umfang auch in den Antwortprozessen geben (Dresel & Tinsner, 2008; Spooren et al., 2013). Des Weiteren ist die vorliegende Datengrundlage dadurch limitiert, dass die Teilnahme freiwillig war (sowohl auf Studierenden- als auch auf Dozierendenseite). Es ist nicht anzunehmen, dass sich dies auf die Güte des Fragebogens auswirkt, jedoch sind die gefundenen Ausprägungen der Lehrqualität dadurch wohl positiv verzerrt. Ferner ist zu berücksichtigen, dass die Daten über einen längeren Zeitraum erhoben wurden und dass Studierende mehrmals in der Stichprobe enthalten sind und mehrere Veranstaltungen evaluierten. Da die Studierendeneinschätzungen der Lehrqualität zum Teil auch auf die Merkmale der evaluierenden Studierenden selbst zurückgeführt werden können (Feistauer & Richter, 2017), mag eine Überschätzung der Korrelationen auf Studierendenebene resultiert (für die Veranstaltungsebene trifft diese Limitation angesichts der reliablen Messung auf dieser Ebene nicht zu) und die ML-Schätzungen beeinflusst haben.

Resümierend kann trotz der Limitationen festgehalten werden, dass mit der vorgelegten deutschsprachigen Adaption des SEEQ ein Instrument zur Verfügung steht, mit dem die multifaktorielle Qualität von Lehrveranstaltungen im Hochschulbereich international an-

schlussfähig, transparent und ökonomisch erfasst werden kann und für das umfangreiche Hinweisen für eine valide Interpretation der Testergebnisse gemäß der intendierten Verwendung als Evaluations- und Forschungsinstrument vorliegen.

Literatur

- Abrami, P. C., d'Apollonia, S. & Rosenfield, S. (2007). The dimensionality of student ratings of instruction: What we know and what we do not. In R. P. Perry and J. C. Smart (Eds.), *The scholarship of teaching and learning in higher education: An evidence-based perspective* (pp. 385–456). Dordrecht, Netherlands: Springer.
- Byrne, B. (2013). *Structural equation modeling with Mplus*. New York, NY: Routledge.
- Chen, F. (2007). Sensitivity of goodness of fit indexes to lack of measurement invariance. *Structural Equation Modeling*, 14(3), 464–504. <https://doi.org/10.1080/10705510701301834>
- Cheung, G. & Rensvold, R. (2002). Evaluating goodness-of-fit indexes for testing measurement invariance. *Structural Equation Modeling*, 9(2), 233–255. https://doi.org/10.1207/S15328007SEM0902_5
- Daumiller, M., Janke, S., Hein, J., Rinas, R., Dickhäuser, O. & Dresel, M. (2021). Do teachers' achievement goals and self-efficacy beliefs matter for students' learning experiences? Evidence from two studies on perceived teaching quality and emotional experiences. *Learning and Instruction*. Advanced online publication. <https://doi.org/10.1016/j.learninstruc.2021.101458>
- Döring, N. (2005). Für Evaluation und gegen Evaluitis. In B. Berendt, H.-P. Voss & J. Wildt (Hrsg.), *Neues Handbuch Hochschullehre*. (S. 2–22). Berlin: Raabe.
- Dresel, M. & Rindermann, H. (2011). Counseling university instructors based on student evaluations of their teaching effectiveness. *Research in Higher Education*, 52, 717–737. <https://doi.org/10.1007/s11162-011-9214-7>
- Dresel, M. & Tinsner, K. (2008). Onlineevaluation von Lehrveranstaltungen. *Zeitschrift für Evaluation*, 7(2), 183–211.
- Dunn, T., Baguley, T. & Brunsden, V. (2014). From alpha to omega. *British Journal of Psychology*, 105(3), 399–412. <https://doi.org/10.1111/bjop.12046>
- Fan, X. & Sivo, S. (2007). Sensitivity of fit indices to model misspecification and model types. *Multivariate Behavioral Research*, 42(3), 509–529. <https://doi.org/10.1080/00273170701382864>
- Feistauer, D. & Richter, T. (2017). How reliable are students' evaluations of teaching quality? *Assessment & Evaluation in Higher Education*, 42(8), 1263–1279. <https://doi.org/10.1080/02602938.2016.1261083>
- Feldman, K. (1976). The superior college teacher from the students' view. *Research in Higher Education*, 5, 243–288. <https://doi.org/10.1007/BF00991967>
- Fincher, C. (1985). Learning theory and research. In J. Smart (Ed.), *Higher education* (pp. 63–96). New York, NY: Athlone.

- Fondel, E., Lischetzke, T., Weis, S. & Gollwitzer, M. (2015). Zur Validität von studentischen Lehrveranstaltungsevaluationen. *Diagnostica*, 61(3), 124–135. <https://doi.org/10.1026/0012-1924/a000141>
- Gravetter, F. & Wallnau, L. (2014). *Essentials of statistics for the behavioral sciences* (8th ed.). Belmont, CA: Wadsworth.
- Helmke, A. (1996). Studentische Evaluation der Lehre. *Zeitschrift für Pädagogische Psychologie*, 10(3/4), 181–186.
- Holman, R. & Glas, C. A. (2005). Modelling non-ignorable missing-data mechanisms with item response theory models. *British Journal of Mathematical and Statistical Psychology*, 58(1), 1–17. <https://doi.org/10.1348/000711005x47168>
- Janke, S., Hein, J., Daumiller, M., Rinas, R., Erdfelder, E., Dresel, M. & Dickhäuser, O. (2020). Open Access Evaluation. *Qualität in der Wissenschaft*, 4.
- Kline, R. (2015). *Principles and practice of structural equation modeling*. New York: Guilford.
- Lüdtke, O., Robitzsch, A., Trautwein, U. & Kunter, M. (2009). Assessing the impact of learning environments: How to use student ratings of classroom or school characteristics in multilevel modeling. *Contemporary Educational Psychology*, 34(2), 120–131. <https://doi.org/10.1016/j.cedpsych.2008.12.001>
- Marsh, H. (1982). SEEQ: A reliable, valid, and useful instrument for collecting students' evaluations of university teaching. *British Journal of Educational Psychology*, 52(1), 77–95. <https://doi.org/10.1111/j.2044-8279.1982.tb02505.x>
- Marsh, H. (2007). Students' evaluations of university teaching. In R. Perry & J. Smart (Eds.), *The scholarship of teaching and learning in higher education* (pp. 319–383). Dordrecht, Netherlands: Springer.
- Marsh, H. & Dunkin, M. (1992). Students' evaluations of university teaching. *International Journal of Educational Research*, 11(3), 253–388. [https://doi.org/10.1016/0883-0355\(87\)90001-2](https://doi.org/10.1016/0883-0355(87)90001-2)
- Marsh, H., Hau, K., Chung, C. & Siu, T. (1998). Confirmatory factor analyses of Chinese students' evaluations of university teaching. *Structural Equation Modeling*, 5(2), 143–164. <https://doi.org/10.1080/10705519809540097>
- Marsh, H. & Hocevar, D. (1991). Students' evaluations of teaching effectiveness. *Teaching and Teacher Education*, 7(4), 303–314. [https://doi.org/10.1016/0742-051X\(91\)90001-6](https://doi.org/10.1016/0742-051X(91)90001-6)
- Marsh, H., Muthén, B., Asparouhov, T., Lüdtke, O., Robitzsch, A., Morin, A. et al. (2009). Exploratory structural equation modeling. *Structural Equation Modeling*, 16(3), 439–476. <https://doi.org/10.1080/10705510903008220>
- Marsh, H., Overall, J. & Kesler, S. (1979). Class size, students' evaluations, and instructional effectiveness. *American Educational Research Journal*, 16(1), 57–70. <https://doi.org/10.3102%2F00028312016001057>
- Marsh, H. & Roche, L. (1997). Making students' evaluations of teaching effectiveness effective. *American Psychologist*, 52(11), 1187–1197. <https://doi.org/10.1037/0003-066X.52.11.1187>
- Muthén, L. & Muthén, B. (2017). *Mplus User's guide*. Los Angeles, CA: Muthén & Muthén.
- Perry, R. & Smart, J. (Eds.). (2007). *The scholarship of teaching and learning in higher education*. Dordrecht, Netherlands: Springer.
- Peugh, J. & Enders, C. (2004). Missing data in educational research. *Review of Educational Research*, 74(4), 525–556. <https://doi.org/10.3102%2F00346543074004525>
- Rindermann, H. (2009). *Lehrevaluation* (2. Aufl.). Landau: VEP.
- Schermelleh-Engel, K., Moosbrugger, H. & Müller, H. (2003). Evaluating the fit of structural equation models. *Methods of Psychological Research Online*, 8, 23–74.
- Sengewald, E. (2016). *Überprüfung und Anwendung von Multilevel-Messmodellen für Fragebögen zur Lehrveranstaltungsevaluation* (Doktorarbeit). Friedrich-Schiller-Universität Jena, Jena.
- Sengewald, E. & Vetterlein, A. (2015). Multilevel Faktorenanalyse für Fragebögen zur Lehrveranstaltungsevaluation. *Diagnostica*, 61(3), 116–123. <https://doi.org/10.1026/0012-1924/a000140>
- Snijders, T. A. B. & Bosker, R. J. (2020). *Multilevel analysis* (2nd ed.). London, UK: Sage.
- Spinath, B., Antoni, C., Bühner, M., Elsner, B., Erdfelder, E., Fydrich, T. et al. (2018). Empfehlungen zur Qualitätssicherung in Studium und Lehre. *Psychologische Rundschau*, 69(3), 183–192. <https://doi.org/10.1026/0033-3042/a000408>
- Spinath, B. & Stehle, S. (2011). Evaluation von Hochschul-lehre. In L. Hornke & M. Amelang (Hrsg.), *Enzyklopädie der Psychologie* (S. 617–667). Göttingen: Hogrefe.
- Spooren, P., Brockx, B. & Mortelmans, D. (2013). On the validity of student evaluation of teaching: The State of the Art. *Review of Educational Research*, 83(4), 598–642. <https://doi.org/10.3102%2F0034654313496870>
- Staufenbiel, T., Seppelfricke, T. & Rickers, J. (2016). Prädiktoren studentischer Lehrveranstaltungsevaluationen. *Diagnostica*, 62(1), 44–59. <https://doi.org/10.1026/0012-1924/a000142>
- Stehle, S., Spinath, B. & Kadmon, M. (2012). Measuring teaching effectiveness: Correspondence between students' evaluations of teaching and different measures of student learning. *Research in Higher Education*, 53, 888–904. <https://doi.org/10.1007/s11162-012-9260-9>
- Stehle, S. & Spinath, B. (2011). Zur Validität studentischer Lehrbeurteilungen. In M. Krämer, S. Preiser & K. Brusdeylins (Hrsg.), *Psychologiedidaktik und Evaluation VII*. (S. 347–356). Aachen: Shaker.

- Toland, M. & De Ayala, R. (2005). A multilevel factor analysis of students' evaluations of teaching. *Educational and Psychological Measurement*, 65(2), 272–296. <https://doi.org/10.1177%2F0013164404268667>
- Vetterlein, A. & Sengewald, E. (2015). Ergebnisdarstellung in der Lehrveranstaltungsevaluation. *Diagnostica*, 61(3), 153–162. <https://doi.org/10.1026/0012-1924/a000128>
- Watkins, D. (1994). Student evaluations of university teaching: A cross-cultural perspective. *Research in Higher Education*, 35, 251–266. <https://doi.org/10.1007/BF02496704>

Note. This is a pre-copyedited, author-produced PDF of an article accepted for publication in *Diagnostica* following peer review. This paper is not the copy of record and may not exactly replicate the final, authoritative version of the article. The final article will be available, upon publication, via its DOI.

Elektronische Supplemente (ESM)

ESM 1. Beispiele für im deutschsprachigen Raum verwendete Instrumente zur Erfassung von Lehrqualität sowie internationale Übersetzungen des SEEQ

Beispiele für im deutschsprachigen Raum verwendete multifaktorielle Instrumente zur Erfassung von Lehrqualität

- Braun, E., Gusy, B., Leidner, B. & Hannover, B. (2008). Das Berliner Evaluationsinstrument für selbsteingeschätzte, studentische Kompetenzen. *Diagnostica*, 54(1), 30–42. <https://doi.org/10.1026/0012-1924.54.1.30>
- Rindermann, H. (2009). *Lehrevaluation* (2. Aufl.). Landau: VEP.
- Gediga, G., von Kannen, K., Schnieder, F., Köhne, S., Luck, H. & Schneider, B. (2000). *KIEL*. Bissendorf: Methodos.
- Thiel, F., Blüthmann, I. & Watermann, R. (2012). Konstruktion eines Fragebogens zur Erfassung der Lehrkompetenz (LeKo). In B. Berendt & H. Voss (Hrsg.), *Neues Handbuch Hochschullehre*. Berlin: Raabe.
- Basler, H., Bolm, G., Dickescheid, T. & Herda, C. (1995). Marburger Fragebogen zur Akzeptanz der Lehre. *Diagnostica*, 41, 62–79.
- Gollwitzer, M. & Schlotz, W. (2003). Das „Trierer Inventar zur Lehrveranstaltungsevaluation“. In G. Krampen & H. Zayer (Hrsg.), *Psychologiedidaktik und Evaluation* (S. 114–128). Bonn: DPV.
- Staufenbiel, T. (2000). Fragebogen zur Evaluation von universitären Lehrveranstaltungen durch Studierende und Lehrende. *Diagnostica*, 46(4), 169–181. <https://doi.org/10.1026/0012-1924.46.4.169>

Beispiele für internationale Übersetzungen des SEEQ

- Al-Muslim, M. & Arifin, Z. (2015). The usability of SEEQ in quality evaluation of Arabic secondary education in Malaysia. *International Education Studies*, 8(3), 202–211. <https://doi.org/10.5539/ies.v8n3p202>
- Balam, E. M. & Shannon, D. M. (2010). Student ratings of college teaching: A comparison of faculty and their students. *Assessment & Evaluation in Higher Education*, 35(2), 209–221. <https://doi.org/10.1080/02602930902795901>
- Coffey, M. & Gibbs, G. (2001). The evaluation of the Student Evaluation of Educational Quality Questionnaire (SEEQ) in UK higher education. *Assessment & Evaluation in Higher Education*, 26(1), 89–93. <https://doi.org/10.1080/02602930020022318>
- Grammatikopoulos, V., Linardakis, M., Gregoriadis, A. & Oikonomidis, V. (2015). Assessing the Students' Evaluations of Educational Quality (SEEQ) questionnaire in Greek higher education. *Higher Education*, 70, 395–408. <https://doi.org/10.1007/s10734-014-9837-7>
- Jarernvonggrayab, A. (2007). The validity evidence of first order and higher order factor structure of Thai version of Marsh's Students' Evaluation of Educational Quality. In *Proceedings of the Redesigning Pedagogy*, Singapore, May 2007.
- Tale'pasand, S., Nazifi, M. & Bigdeli, I. (2009). Validation of the Iranian version of student's evaluation of educational quality questionnaire. *International Journal of Behavioral Sciences*, 3, 127–134.
- Watkins, D. & Thomas, B. (1991). Assessing teaching effectiveness: An Indian perspective. *Assessment and Evaluation in Higher Education*, 16(3), 185–198. <https://doi.org/10.1080/0260293910160302>

ESM 2. Items des SEEQ-DE

SEEQ-DE	Original SEEQ
Lernzuwachs^a	Learning/Value
1. Ich habe in dieser Veranstaltung Dinge gelernt, die sinnvoll und wichtig sind.	You have learned something which you consider valuable.
2. Mein Interesse an den behandelten Inhalten ist durch diese Veranstaltung gestiegen.	Your interest in the subject has increased as a consequence of this course.
3. Den Stoff dieser Veranstaltung habe ich verstanden.	You have learned and understood the subject materials in this course.
4. Ich habe viel in dieser Veranstaltung dazu gelernt.	—
5. Diese Veranstaltung regt mich zum Nachdenken an.	You find the course intellectually challenging and stimulating.
Gesamtbeurteilung^b	Overall Course Rating
36. Wie schneidet diese Veranstaltung im Vergleich zu anderen Lehrveranstaltungen ab, die Sie belegt haben?	How does this course compare with other courses you have had?
37. Wie schneidet diese Lehrperson im Vergleich zu anderen Lehrpersonen ab, die Sie hatten?	How does this instructor compare with other instructors you have had?
39. Welche Note geben Sie der Veranstaltung insgesamt?*	—
40. Welche Note geben Sie der Lehrperson insgesamt?*	—
Engagement der Lehrperson^a	Instructor Enthusiasm
6. Die Lehrperson ist begeistert von ihrer Lehrtätigkeit.	Instructor is enthusiastic about teaching the course.
7. Die Lehrperson hält die Veranstaltung dynamisch und aktiv.	Instructor is dynamic and energetic in conducting the course.
8. Die Lehrperson nutzt Humor, um ihre Darstellungen anschaulicher zu machen.	Instructor enhances presentations with the use of humor.
9. Durch die Art und Weise, wie die Lehrperson die Inhalte darstellt, bleibt mein Interesse während der Sitzungen aufrechterhalten.	Instructor's style of presentation held your interest during class.
Strukturierung und Präsentation^a	Organization/Clarity
10. Die Erklärungen der Lehrperson sind verständlich.	Instructor's explanations are clear.
11. Die eingesetzten Materialien (inkl. Medien) sind sorgfältig erstellt und werden genau erklärt.	Course materials are well prepared and carefully explained.
12. Die zu Semesterbeginn angegebenen Inhalte der Veranstaltung stimmen mit den tatsächlich behandelten überein, so dass mir stets klar ist, was als nächstes kommt.	Proposed objectives agree with those actually taught so you know where the course is going.
13. Die Art und Weise, wie die Inhalte (inkl. Medien) präsentiert werden, erleichtert das Anfertigen von eigenen Notizen.	Instructor gives lectures that facilitate taking notes.
14. Die Inhalte werden gut strukturiert.	—
Aktivierung^a	Group Interaction
15. Die Studierenden werden ermuntert, sich an Diskussionen in der Veranstaltung zu beteiligen.	Students are encouraged to participate in class discussions.
16. Die Studierenden werden ermutigt, ihre Ideen und ihr Wissen in die Veranstaltung einzubringen.	Students are invited to share their ideas and knowledge.
17. Die Studierenden werden ermutigt, Fragen zu stellen, und sie erhalten darauf sinnvolle Antworten.	Students are encouraged to ask questions and are given meaningful answers.
18. Die Studierenden werden ermuntert, eigene Ideen und Fragen zu äußern.	Students are encouraged to express their own ideas and/or question the instructor.
Sozialklima^a	Individual Rapport
19. Die Lehrperson ist freundlich zu den Studierenden.	Instructor is friendly towards individual students.
20. Die Lehrperson gibt den Studierenden das Gefühl, während und außerhalb der Veranstaltung bei ihr Hilfe und Unterstützung erhalten zu können.	Instructor makes students feel welcome in seeking help/advice in or outside of class.
21. Die Lehrperson hat ein echtes Interesse am einzelnen Studierenden.	Instructor has a genuine interest in individual students.

22. Die Lehrperson steht den Studierenden außerhalb der Veranstaltung zur Verfügung.	Instructor is adequately accessible to students during office hours or after class.
Breite^a	Breadth of Coverage
23. Die Lehrperson beleuchtet die Inhalte von verschiedenen Seiten.	Instructor contrasts the implications of various theories.
24. Die Lehrperson stellt die Hintergründe der vorgestellten Inhalte dar.	Instructor presents the background or origin of ideas/concepts developed in class.
25. Bei passenden Themen präsentiert die Lehrperson Sichtweisen, die sich von ihren eigenen unterscheiden.	Instructor presents points of view other than his/her own when appropriate.
26. Die Lehrperson bringt aktuelle wissenschaftliche Entwicklungen in die Veranstaltung ein.	Instructor adequately discusses current developments in field.
Leistungsbewertung^a	Examinations/Grading
27. Es gibt nützliches Feedback auf Beiträge von Studierenden (z.B. Wortbeiträge, Referate, Hausaufgaben, Prüfungen).	Feedback on examinations/graded materials is valuable.
28. Die Art, wie Beiträge von Studierenden (z.B. Prüfungen, Beiträge in der Veranstaltung) bewertet werden, entspricht den vorab angekündigten Kriterien.	Examinations/graded materials test course content as emphasized by instructor.
29. Die Art, wie Beiträge von Studierenden (z.B. Prüfungen, Beiträge in der Veranstaltung) bewertet werden, ist gerecht und angemessen.	Methods of evaluating student work are fair and appropriate.
Aufgaben^a	Assignments/Readings
30. Die vorgeschriebene Begleitliteratur ist nützlich.	Required readings /texts are valuable.
31. Begleitliteratur, Hausaufgaben usw. tragen zum besseren Verständnis der Lerninhalte bei.	Readings, homeworks, etc., contribute to appreciation and understanding of the subject.
Studentische Beiträge^{a,*}	—
32. Die Lehrperson wählt passende Themen für Beiträge von Studierenden (z.B. Referate, Inputs, Gruppenarbeiten) aus.*	—
33. Die Qualität der Beiträge von Studierenden (z.B. Referate, Inputs, Gruppenarbeiten) ist hoch.*	—
34. Ich lerne viel von den Beiträgen meiner Mitstudierenden (z.B. Referate, Inputs, Gruppenarbeiten).*	—
35. Die Lehrperson moderiert und ergänzt Beiträge von Studierenden (z.B. Referate, Inputs, Gruppenarbeiten) in sinnvoller Weise.*	—
Hintergrundvariable: Aufwand/Anspruch der Veranstaltung^c	Workload/Difficulty
41. Wie schätzen Sie den Schwierigkeitsgrad dieser Veranstaltung ein?	Course difficulty, relative to other courses, is:
42. Wie schätzen Sie den Arbeitsaufwand dieser Veranstaltung ein?	Course workload, relative to other courses, is:
43. Wie schätzen Sie das Tempo dieser Veranstaltung ein?	Course pace, relative to other courses, is:
Weitere Hintergrundvariablen	Student and course characteristics
38. Was denken Sie, wie gut werden Sie in der Veranstaltung abschneiden? ^b	Your expected grade in the course
44. Wie hoch war Ihr Interesse am Thema vor Beginn der Veranstaltung? ^c	Your level of interest in the subject prior to this course
45. Arbeitsaufwand pro Woche für die Veranstaltung in Stunden (ohne Anwesenheit): ^d	Hours per week required outside of class
46. Wie gut sind Ihre bisherigen Leistungen im Studium (geschätzter Durchschnitt aller Prüfungen, ggf. runden)? ^e	Your overall grade point average
47. Warum besuchen Sie diese Veranstaltung (nur wichtigsten Grund nennen)? ^f	Your reason for taking the course
48. Im wievielten Semester studieren Sie in Ihrem aktuellen Studiengang (Fachsemester)? ^g	Your year in school
49. Geschlecht ^h	Sex

Offene Frage zur Erfassung spezifischer Stärken und Schwächen

50. Was ist besonders gut, was ist besonders schlecht an der Veranstaltung? Bitte bemühen Sie sich um möglichst konkrete Antworten!

Open Question

Do you have any comments to add about your overall evaluation of the course?

Anmerkungen: Originalitems und Originalbezeichnungen der Faktoren in eckigen Klammern. Alle Items werden, sofern nicht anders angegeben, mit fünfstufigen Antwortskalen vorgegeben. Die mit * markierten Fragebogenteile sind gegenüber dem Original SEEQ neu und stellen optionale Fragebogenteile dar, die je nach Evaluationskontext hinzugefügt werden können.

^a Antwortskalen von 1 (*stimme gar nicht zu*) bis 5 (*stimme voll zu*), zusätzliche Antwortmöglichkeit *nicht beurteilbar*.

^b Antwortskalen von 1 (*mangelhaft*) bis 5 (*sehr gut*). ^c Antwortskalen von 1 (*sehr gering*) bis 5 (*sehr hoch*).

^d Antwortmöglichkeiten: „0 Stunden“, „0–1 Stunden“, „2–3 Stunden“, „4–5 Stunden“, „6–7 Stunden“, „mehr als 7 Stunden“. ^e Antwortmöglichkeiten: „1.0–1.5“, „1.6–2.5“, „2.6–3.5“, „3.6–4.5“, „schlechter als 4.5“.

^f Antwortmöglichkeiten: „Pflicht“, „Wahlpflicht“, „Termin“, „Interesse“, „Prüfungsvorbereitung“.

^g Antwortmöglichkeiten: „1.–2. Semester“, „3.–4. Semester“, „5.–6. Semester“, „7.–8. Semester“, „9.–10. Semester“, „11. oder höher“. ^h Antwortmöglichkeiten: „männlich“, „weiblich“.

Markierung: ☐ ☒ ☐ ☐ Bitte verwenden Sie einen Kugelschreiber oder einen nicht zu starken Filzstift
 Dieser Fragebogen wird maschinell erfasst.
 Korrektur: ☐ ☒ ☐ ☐ Bitte beachten Sie im Interesse einer optimalen Datenerfassung die links gegebenen
 Hinweise beim Ausfüllen.

Fragebogen zur Evaluation von Lehrveranstaltungen

Liebe Studierende, mit der Beantwortung dieses Fragebogens unterstützen Sie die Qualitätssicherung im Bereich der Lehrveranstaltungen. Denken Sie beim Beurteilen an alle bisherigen Sitzungen in diesem Semester. Vielen Dank für Ihre Mithilfe!
 Fragen oder Anregungen zur Evaluation bitte an evaluation@qa.uni-augsburg.de (www.uni-augsburg.de/einrichtungen/qa/)

Studiengang: 100er ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐
 10er ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐
 1er ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐ ☐
 Bitte kreuzen Sie für Ihren Studiengang (Hauptfach) die entsprechenden 3 Nummern an
 x0 x1 x2 x3 x4 x5 x6 x7 x8 x9

Beispiel: Sozialwissenschaften B.A. mit der Kennziffer 411: 4 bei 100er / 1 bei 10er / 1 bei 1er

	stimme gar nicht zu		stimme voll zu	nicht beurteil- bar
1. Ich habe in dieser Veranstaltung Dinge gelernt, die sinnvoll und wichtig sind.	☐	☐	☐	☐
2. Mein Interesse an den behandelten Inhalten ist durch diese Veranstaltung gestiegen.	☐	☐	☐	☐
3. Den Stoff dieser Veranstaltung habe ich verstanden.	☐	☐	☐	☐
4. Ich habe viel in dieser Veranstaltung dazu gelernt.	☐	☐	☐	☐
5. Diese Veranstaltung regt mich zum Nachdenken an.	☐	☐	☐	☐
6. Die Lehrperson ist begeistert von ihrer Lehrfähigkeit.	☐	☐	☐	☐
7. Die Lehrperson hält die Veranstaltung dynamisch und aktiv.	☐	☐	☐	☐
8. Die Lehrperson nutzt Humor, um ihre Darstellungen anschaulicher zu machen.	☐	☐	☐	☐
9. Durch die Art und Weise, wie die Lehrperson die Inhalte darstellt, bleibt mein Interesse während der Sitzungen aufrechterhalten.	☐	☐	☐	☐
10. Die Erklärungen der Lehrperson sind verständlich.	☐	☐	☐	☐
11. Die eingesetzten Materialien (inkl. Medien) sind sorgfältig erstellt und werden genau erklärt.	☐	☐	☐	☐
12. Die zu Semesterbeginn angegebenen Inhalte der Veranstaltung stimmen mit den tatsächlich behandelten überein, so dass mir stets klar ist, was als nächstes kommt.	☐	☐	☐	☐
13. Die Art und Weise, wie die Inhalte (inkl. Medien) präsentiert werden, erleichtert das Anfertigen von eigenen Notizen.	☐	☐	☐	☐
14. Die Inhalte werden gut strukturiert.	☐	☐	☐	☐
15. Die Studierenden werden ermuntert, sich an Diskussionen in der Veranstaltung zu beteiligen.	☐	☐	☐	☐
16. Die Studierenden werden ermutigt, ihre Ideen und ihr Wissen in die Veranstaltung einzubringen.	☐	☐	☐	☐
17. Die Studierenden werden ermutigt, Fragen zu stellen, und sie erhalten darauf sinnvolle Antworten.	☐	☐	☐	☐
18. Die Studierenden werden ermuntert, eigene Ideen und Fragen zu äußern.	☐	☐	☐	☐
19. Die Lehrperson ist freundlich zu den Studierenden.	☐	☐	☐	☐
20. Die Lehrperson gibt den Studierenden das Gefühl, während und außerhalb der Veranstaltung bei ihr Hilfe und Unterstützung erhalten zu können.	☐	☐	☐	☐
21. Die Lehrperson hat ein echtes Interesse am einzelnen Studierenden.	☐	☐	☐	☐
22. Die Lehrperson steht den Studierenden außerhalb der Veranstaltung zur Verfügung.	☐	☐	☐	☐
23. Die Lehrperson beleuchtet die Inhalte von verschiedenen Seiten.	☐	☐	☐	☐
24. Die Lehrperson stellt die Hintergründe der vorgestellten Inhalte dar.	☐	☐	☐	☐
25. Bei passenden Themen präsentiert die Lehrperson Sichtweisen, die sich von ihren eigenen unterscheiden.	☐	☐	☐	☐
26. Die Lehrperson bringt aktuelle wissenschaftliche Entwicklungen in die Veranstaltung ein.	☐	☐	☐	☐

	stimme gar nicht zu			stimme voll zu	nicht beurteil- bar
27. Es gibt nützliches Feedback auf Beiträge von Studierenden (z.B. Wortbeiträge, Referate, Hausaufgaben, Prüfungen).	☐	☐	☐	☐	☐
28. Die Art, wie Beiträge von Studierenden (z.B. Prüfungen, Beiträge in der Veranstaltung) bewertet werden, entspricht den vorab angekündigten Kriterien.	☐	☐	☐	☐	☐
29. Die Art, wie Beiträge von Studierenden (z.B. Prüfungen, Beiträge in der Veranstaltung) bewertet werden, ist gerecht und angemessen.	☐	☐	☐	☐	☐
30. Die vorgeschriebene Begleitliteratur ist nützlich.	☐	☐	☐	☐	☐
31. Begleitliteratur, Hausaufgaben usw. tragen zum besseren Verständnis der Lerninhalte bei.	☐	☐	☐	☐	☐
32. Die Lehrperson wählt passende Themen für Beiträge von Studierenden (z.B. Referate, Inputs, Gruppenarbeiten) aus.	☐	☐	☐	☐	☐
33. Die Qualität der Beiträge von Studierenden (z.B. Referate, Inputs, Gruppenarbeiten) ist hoch.	☐	☐	☐	☐	☐
34. Ich lerne viel von den Beiträgen meiner Mitstudierenden (z.B. Referate, Inputs, Gruppenarbeiten).	☐	☐	☐	☐	☐
35. Die Lehrperson moderiert und ergänzt Beiträge von Studierenden (z.B. Referate, Inputs, Gruppenarbeiten) in sinnvoller Weise.	☐	☐	☐	☐	☐

	mangelhaft			sehr gut
36. Wie schneidet diese Veranstaltung im Vergleich zu anderen Lehrveranstaltungen ab, die Sie belegt haben?	☐	☐	☐	☐
37. Wie schneidet diese Lehrperson im Vergleich zu anderen Lehrpersonen ab, die Sie hatten?	☐	☐	☐	☐
38. Was denken Sie, wie gut werden Sie in der Veranstaltung abschneiden?	☐	☐	☐	☐
39. Welche Note geben Sie der Veranstaltung insgesamt?	☐	☐	☐	☐
40. Welche Note geben Sie der Lehrperson insgesamt?	☐	☐	☐	☐

	sehr gering			sehr hoch
41. Wie schätzen Sie den Schwierigkeitsgrad dieser Veranstaltung ein?	☐	☐	☐	☐
42. Wie schätzen Sie den Arbeitsaufwand dieser Veranstaltung ein?	☐	☐	☐	☐
43. Wie schätzen Sie das Tempo dieser Veranstaltung ein?	☐	☐	☐	☐
44. Wie hoch war Ihr Interesse am Thema vor Beginn der Veranstaltung?	☐	☐	☐	☐
45. Arbeitsaufwand pro Woche für die Veranstaltung in Stunden (ohne Anwesenheit):	☐ 0 Stunden ☐ bis unter 3 Stunden	☐ bis unter 1 Stunde ☐ bis unter 4 Stunden	☐ bis unter 2 Stunden ☐ über 4 Stunden	
46. Wie gut sind Ihre bisherigen Leistungen im Studium (geschätzter Durchschnitt aller Prüfungen, ggf. runden):	☐ 1,0 - 1,5 ☐ 3,6 - 4,5	☐ 1,6 - 2,5 ☐ schlechter als 4,5	☐ 2,6 - 3,5	
47. Warum besuchen Sie diese Veranstaltung (nur wichtigsten Grund nennen)?	☐ Pflicht ☐ Interesse	☐ Wahlpflicht ☐ Prüfungsvorbereitung	☐ Termin	
48. Im wievielten Semester studieren Sie in Ihrem aktuellen Studiengang (Fachsemester)?	☐ 1. - 2. Semester ☐ 7. - 8. Semester	☐ 3. - 4. Semester ☐ 9. - 10. Semester	☐ 5. - 6. Semester ☐ 11. oder höher	
49. Geschlecht:	☐ männlich	☐ weiblich		
50. Was ist besonders gut, was ist besonders schlecht an der Veranstaltung? Bitte bemühen Sie sich um möglichst konkrete Antworten.				

ESM 4. Durchführungsinstruktion für Testleiter bzw. Dozierende**Hinweise zur Durchführung der Lehrveranstaltungsevaluation**

Liebe Dozentin, lieber Dozent,

herzlichen Dank für Ihre Bereitschaft, an der fakultätsweiten Evaluation von Lehrveranstaltungen mitzuwirken. Sie dient dazu, Ihnen Feedback zur Lehre zu geben und Informationen für den Lehrbericht zu erhalten.

Einsicht in die Ergebnisse der einzelnen Lehrveranstaltungen erhalten lediglich der Studiendekan, die Leiter(innen) der entsprechenden Arbeitseinheiten sowie eine einzelne Mitarbeiterin, die die Fragebögen auswertet. Ergebnisse werden ausschließlich aggregiert (im Lehrbericht) veröffentlicht (nicht auf der Ebene einzelner Veranstaltungen/Dozenten). Persönlich erhalten Sie per Email eine schriftliche Ergebnisrückmeldung.

Das vorgeschlagene Zeitfenster für die Evaluation ist vom XX.XX.XXXX bis YY.YY.YYYY. Wenn möglich bitten Sie die Studierenden, in diesem Zeitfenster die beiliegenden Fragebögen auszufüllen. Zur Sicherstellung eines ausreichenden Rücklaufs sollten diese während der regulären Veranstaltungszeit ausgefüllt werden (Empfehlung: Beginn einer Sitzung). Das Ausfüllen des Fragebogens nimmt etwa 10 Minuten in Anspruch.

Gehen Sie bitte wie folgt vor:

1. Prüfen Sie vorab die Anzahl der Fragebögen. Sollten nicht ausreichend Fragebögen vorhanden sein, sind in Ihrem Sekretariat weitere hinterlegt. Bitte auf keinen Fall Fragebögen einfach kopieren, da diese nicht gescannt und somit nicht ausgewertet werden können.
2. Lassen Sie in der Lehrveranstaltung Studierende die Fragebögen austeilen.
3. Bitten Sie vorab die Studierenden, ihren Studiengang in den Fragebogen einzutragen. Lesen Sie dazu die Nummer(n) des Studiengangs/ der Studiengänge in Ihrer Veranstaltung vor. Eine Liste der Studiengänge findet sich auf der Rückseite des Deckblattes zu Ihrer Veranstaltung.
4. Lesen Sie folgende Erläuterung/Instruktion vor:

Liebe Studierende,

bitte schätzen Sie anhand des Fragebogens diese Lehrveranstaltung ein. Beachten Sie hierbei nicht nur den heutigen Termin. Beantworten Sie jede Aussage möglichst genau und differenziert. Alle Ergebnisse werden anonymisiert ausgewertet. Sie werden dazu verwendet, künftige Lehrveranstaltungen zu optimieren und an die Dozierenden in anonymisierter Form rückgemeldet. Mit ihrer sorgfältigen Beantwortung unterstützen Sie die Bemühungen um eine effektive Lehre. Bitte verwenden Sie nur schwarze Stifte und machen Sie die Kreuze sauber und eindeutig.

Vielen Dank für Ihre Teilnahme.

5. Bitten Sie eine(n) Studierende(n), die Fragebögen einzusammeln und gemeinsam mit dem Deckblatt in das Kuvert zu stecken und es zu verschließen. Hierbei sollte das Deckblatt oben auf liegen.
6. Schicken Sie das verschlossene Kuvert bitte zeitnah per Hauspost an ZZZ.

Noch ein Hinweis zur Teilnehmerzahl bei der Evaluation: Die Messgenauigkeit des Fragebogens sinkt bei einer Teilnehmeranzahl von weniger als neun Personen unter eine kritische Grenze. Zudem ist in diesem Fall die Anonymität der Studierenden eingeschränkt. Daher werden nur Veranstaltungen ausgewertet, für die mindestens acht ausgefüllte Evaluationsbögen vorliegen.

Vielen Dank für Ihre Beteiligung! Bei Fragen können Sie sich gerne an mich wenden.

Beste Grüße

ESM 5. Ergebnisse der Faktorenanalysen

	<i>df</i>	χ^2	CFI	TLI	RMSEA	SRMR	
						within	between
ESEM Analyse auf Veranstaltungsebene (<i>N</i> = 3 660)							
1-Faktor Modell	702	64 918	.588	.565	.164	.095	
10-Faktoren Modell	396	7 879	.958	.921	.070	.016	
Konfirmatorische 2-Ebenen-Analysen: Studierende (<i>N</i> = 76 687) in Veranstaltungen (<i>N</i> = 3 660)							
1-Faktor Modell	1 442	471 894	.642	.633	.067	.077	.110
10-Faktoren Modell	1 339	115 276	.913	.904	.034	.041	.076
Multi-Gruppen Modelle							
Konfigurale Messinvarianz	3 983	113 841	.911	.901	.035	.035	.063
Metrische Messinvarianz	4 053	115 485	.910	.901	.034	.035	.063
Skalare Messinvarianz	4 132	118 954	.907	.900	.035	.035	.064

Anmerkungen: Multi-Gruppen-Modelle: 797 Übungen ($n = 24\,699$ Studierende), 2 497 Seminare ($n = 41\,415$) und 105 Vorlesungen ($n = 5\,447$). Neben dem postulierten 10-Faktoren Modell berichten wir zum Vergleich die Ergebnisse eines 1-Faktor-Modells, das nicht zwischen den verschiedenen SEEQ-Dimensionen der Lehrqualität unterscheidet.

ESM 6. Ergebnisse der ESEM-Analyse zur Faktorstruktur auf Veranstaltungsebene

	F1	F2	F3	F4	F5	F6	F7	F8	F9	F10
Lernzuwachs										
Sinnvolles und Wichtiges gelernt	.58	.09	.03	.14	.03	.04	.09	.03	.13	.10
Interesse gestiegen	.60	.02	.08	-.02	.05	.07	.17	.01	.15	.16
Stoff verstanden	.31	-.10	.10	.25	.12	.08	.01	-.48	-.05	.28
Viel dazugelernt	.54	.07	.09	.16	.03	.05	.07	.13	.13	.16
Zum Nachdenken angeregt	.45	-.02	.01	-.14	.19	.03	.34	.07	.19	.09
Gesamtbeurteilung										
Abschneiden der Lehrveranstaltung	.48	.38	.14	.10	.05	.04	-.03	-.02	.11	.10
Abschneiden des Dozierenden	.07	.60	.25	.05	.04	.13	.07	.03	.06	.01
Note für Lehrveranstaltung	.46	.36	.13	.12	.04	.07	.01	-.03	.12	.10
Note für Dozierenden	.07	.59	.23	.08	.04	.15	.07	.02	.07	.02
Engagement der Lehrperson										
Begeistert von Lehrtätigkeit	.01	.22	.46	.01	.12	.16	.22	-.03	.05	.01
Dynamisch und aktiv	.05	.17	.66	.12	.12	.06	.04	.03	.03	.04
Einsatz von Humor	-.01	.14	.63	-.05	.05	.05	.12	-.09	.09	.08
Interesse bleibt aufrecht	.22	.16	.51	.14	.06	.06	.04	.06	.11	.06
Stoffstrukturierung und -präsentation										
Erklärungen verständlich	.10	.27	.14	.40	.08	.10	.11	-.18	-.02	.03
Sorgfältig erstellt, genau erklärt	.02	.07	.14	.64	-.02	.10	.05	-.04	.03	.07
Übereinstimmung der Inhalte	-.02	.18	-.27	.43	.06	.02	.14	-.06	.18	.02
Präsentation gut für Notizen	.07	-.03	.12	.61	.01	.11	-.01	.03	.15	.05
Inhalte gut strukturiert	.06	.11	-.01	.74	.01	.04	.05	.02	.11	.04
Aktivierung der Studierenden										
Beteiligung an Diskussionen	.02	.02	.05	-.03	.73	.01	.15	-.03	.04	.17
Ideen/Wissen einbringen	.02	.02	.06	-.03	.74	.04	.11	-.04	.05	.18
Fragen stellen und gute Antworten	.09	.15	.09	.13	.59	.16	.03	.05	.09	-.01
Ideen und Fragen äußern	.05	.06	.09	.04	.72	.14	.03	.02	.09	.07
Sozialklima										
Freundlich	-.07	.42	.05	.04	.09	.40	.01	-.08	.07	-.07
Unterstützung	.02	.09	.04	.07	.04	.83	.02	.01	.03	.01
Echtes Interesse an Studierenden	.05	.08	.19	.01	.06	.62	.05	-.01	.09	.09
Hilfe außerhalb der Veranstaltung	.02	.01	-.05	.03	.05	.74	.09	.04	.08	.09
Stoffbreite										
Verschiedene Seiten	.10	.09	.14	.07	.09	.12	.54	.04	.10	.06
Hintergründe der Inhalte	.09	.07	.13	.12	.03	.09	.62	.01	.08	.05
Unterschiedliche Sichtweisen	.05	.07	.07	.02	.09	.08	.51	.02	.13	.09
Aktuelle Entwicklungen	-.02	-.04	-.02	.02	.10	.03	.61	-.01	.07	.15
Leistungsbewertung										
Nützliches Feedback	.03	.04	-.02	-.04	.03	-.01	.04	.96	.07	.01
Bewertung wie vorab angekündigt	.04	-.08	-.05	.04	.11	.05	-.05	.78	-.09	.10
Bewertung gerecht	.04	-.03	.10	.06	-.13	.02	.02	.77	.03	.01
Aufgaben										
Begleitliteratur nützlich	-.03	-.03	-.01	-.02	-.02	.01	.07	-.04	.79	.05
Begleitliteratur gut für Verständnis	.06	.01	.02	.06	.02	.04	-.06	.08	.79	.01
Studentische Beiträge										
Passende Themen für Beiträge	-.04	.10	-.03	.07	.12	.07	.14	-.12	.26	.43
Qualität der Beiträge hoch	.04	-.02	.04	.05	.05	.04	.02	.04	.04	.79
Hoher Lernzuwachs durch Beiträge	.09	.01	.01	-.03	.07	.04	.05	.04	.08	.79
Sinnvolle Ergänzungen	-.04	.28	.02	.06	.21	.05	.21	-.01	.12	.31

Anmerkungen: N = 3 660 Veranstaltungen. Berichtet sind die rotierten Faktorladungen der ESEM-Analyse mit Geomin-Rotation und 10 Faktoren basierend auf den auf Veranstaltungsebene aggregierten Item-Mittelwerten. Alle Parameterschätzungen sind vollständig standardisiert. Basierend auf den Ergebnissen von Marsh et al. (2009) a priori angenommene Ladungen sind grau hinterlegt.

ESM 7. Ergebnisse der Faktorenanalysen ohne den Faktor „Studentische Beiträge“

						SRMR	
	<i>df</i>	χ^2	CFI	TLI	RMSEA	within	between
ESEM Analyse auf Veranstaltungsebene (<i>N</i> = 3 660)							
9-Faktoren Modell	316	6 343	.957	.920	.075		.012
Konfirmatorische 2-Ebenen-Analysen: Studierende (<i>N</i> = 76 687) in Veranstaltungen (<i>N</i> = 3 660)							
9-Faktoren Modell	1 070	93 398	.924	.916	.034	.036	.074
Multi-Gruppen Modelle							
Konfigurale Messinvarianz	3 178	91 456	.923	.913	.035	.031	.062
Metrische Messinvarianz	3 243	93 015	.922	.914	.034	.032	.062
Skalare Messinvarianz	3 314	96 448	.919	.912	.035	.031	.063

Anmerkungen: Multi-Gruppen-Modelle: 797 Übungen ($n = 24\,699$ Studierende), 2 497 Seminare ($n = 41\,415$) und 105 Vorlesungen ($n = 5\,447$).

ESM 8. Mittelwerte und 95%-Konfidenzintervalle aller Subskalen

ESM 9. Beschreibung der Evaluationsergebnisse

Interpretationshilfe zu Ihrem Evaluationsergebnis

Vorbemerkungen

Auf den folgenden Seiten finden Sie Hinweise zur Interpretation des Evaluationsergebnisses Ihrer Lehrveranstaltung und zu möglichen Folgerungen für die Verbesserung der Lehrqualität. Erfasst wird die Lehrqualität in vier Bereichen:

- **Lehrerfolg:** Lehre ist – unabhängig von der Wahl der Mittel – dann erfolgreich, wenn sie übergeordnete Ziele erreicht (z.B. Lernzuwachs, eine positive Gesamtbewertung der Veranstaltung). Der Lehrerfolg bezieht sich auf das Ausmaß, in dem diese Ziele erreicht werden. Falls Ergebnisse verschiedener Veranstaltungen verglichen werden sollen, sollte (nur) der Lehrerfolg herangezogen werden. Wenn Sie diesbezüglich mit Ihren Evaluationsergebnissen zufrieden sind, brauchen Sie nichts weiter zu unternehmen. Sollten Sie noch Anregungen zur Optimierung Ihrer Veranstaltung benötigen, dann orientieren Sie sich bitte an den folgenden Erläuterungen.
- **Didaktisches Handeln:** Darunter sind konkrete Handlungen der Lehrenden subsumiert, die bedeutsam zum Lehrerfolg beitragen. Der Schwerpunkt liegt auf verhaltensnahen Aspekten, die gut beeinflusst werden können (z.B. Strukturierung des Stoffs). Ansatzpunkte zur Verbesserung des Lehrerfolgs lassen sich deshalb am besten anhand des didaktischen Handelns identifizieren. Da unterschiedliches didaktisches Handeln zu Lehrerfolg führen kann, gibt es keinen Prototypen für das beste didaktische Handeln (insbesondere ist es für ein gutes Evaluationsergebnis nicht notwendig, bei allen Teilaspekten überdurchschnittlich abzuschneiden).
- **Merkmale der Lehrperson:** Einschätzung darüber, inwieweit es der Lehrperson mit ihren individuellen Eigenschaften gelingt, Interesse zu wecken und freundlich und unterstützend den Studierenden zur Seite zu stehen.
- **Studentische Bedingungen:** Diese dienen der Einordnung der Ergebnisse und zur Erstellung von Untergruppenauswertungen (z.B. Studiengang, Geschlecht, Vorwissen). Sie sind nicht Teil des Feedbacks.

1. Lehrerfolg

1.1. Lernzuwachs (Fragen 1 – 5)

Einschätzung darüber, wie viel die Studierenden in der Veranstaltung lernen, in welchem Ausmaß sie ein tieferes Verständnis des Veranstaltungsthemas gewinnen und in welchem Ausmaß bei den Studierenden das Interesse am Thema gefördert wird. Dieser Indikator dient – gemeinsam mit dem Indikator „Gesamtbeurteilung“ – der Beurteilung des Lehrerfolgs der Lehrveranstaltung.

1.2. Gesamtbeurteilung (Fragen 36, 37, 39, 40)

Gesamtbewertung der Lehrqualität der Lehrveranstaltung. Sie umfasst die Bewertung der Veranstaltung und die Bewertung der Lehrperson in Bezug auf andere Veranstaltungen respektive anderer Lehrpersonen und in Bezug auf eine Note (1 = mangelhaft, 5 = sehr gut).

2. Didaktisches Handeln

2.1. Stoffstrukturierung/-präsentation (Fragen 10 – 14)

Einschätzung darüber, in welchem Ausmaß der Stoff lernförderlich strukturiert und erklärt wird (z.B. Stoff verständlich erklären, Wichtiges hervorheben oder Stoff vernetzen).

2.2. Aktivierung der Studierenden (Fragen 15 – 18)

Ausmaß, in dem Studierende ermuntert werden, sich aktiv in die Lehrveranstaltung einzubringen (z.B. Einbringen von eigenem Wissen oder Beteiligung an Diskussionen).

2.3. Stoffbreite (Fragen 23 – 26)

Ausmaß, in dem der Stoff mit unterschiedlichen Perspektiven gelehrt wird (z.B. Berücksichtigung verschiedener theoretischer Sichtweisen und Hintergründe, Einbezug aktueller wissenschaftlicher Entwicklungen, Praxisbezüge).

2.4. Leistungsbewertung (Fragen 27 – 29)

Ausmaß, in dem Leistungsbewertungen (z.B. bei Beiträgen in der Lehrveranstaltung) klar vorab angekündigten Kriterien entsprechen, fair sind und einen Nutzen für die Studierenden darstellen.

2.5. Aufgaben (Fragen 30 – 31)

Ausmaß, in dem Haus-/Übungsaufgaben und Begleitliteratur zu einem Verständnis beitragen.

2.6. Studentische Beiträge (Fragen 32 – 35)

Ausmaß, in dem Beiträge von Studierenden (z.B. Diskussionsbeiträge, Referate, Gruppenarbeiten) effektiv für das Lernen sind und sinnvoll durch die Lehrperson moderiert und ergänzt werden.

2.7. Aufwand/Anspruch der Veranstaltung (Fragen 41 – 43)

Ausmaß des Schwierigkeitsgrades, des Arbeitsaufwandes und des Tempos der Veranstaltung.

3. Merkmale der Lehrperson

3.1. Engagement Lehrperson (Fragen 6 – 9)

Einschätzung darüber, wie engagiert die Lehrperson ist, wie sehr sie begeistert und wie es ihr gelingt, die Lehrveranstaltung interessant zu gestalten.

3.2. Sozialklima (Fragen 19 – 22)

Ausmaß, in dem eine freundliche Atmosphäre im Umgang der Lehrperson mit Studierenden besteht (inkl. Interesse an Studierenden, Anliegen Studierender werden ernst genommen).