Running Head: ERFOLGSPROGNOSE IM MASTERSTUDIUM

Bereit für Bologna? Test- und notenbasierte Erfolgsprognose im Masterstudium

Johannes Schult
Landesinstitut für Schulentwicklung, Stuttgart

(Stand: 12. November 2018)

Autoreninformation: Dr. Johannes Schult, Landesinstitut für Schulentwicklung, Heilbronner
Straße 172, D-70191 Stuttgart, Telefon: 0711 6642-3102, Fax: 0711 6642-3098, E-Mail:
jutze@jutze.com

Präregistrierung und Datenanalysebefehle zu dieser Studie stehen online unter
<https://osf.io/3dcjz/> und Details zum Rohdatenzugang unter
<https://dx.doi.org/10.5157/NEPS:SC5:11.0.0>.

Zusammenfassung

Fachspezifische Studierfähigkeitstests haben sich auch im deutschsprachigen Raum als valide Prädiktoren des Bachelorstudienerfolgs und somit als hilfreiche Auswahlinstrumente erwiesen. Anhand der Daten des Nationalen Bildungspanels (NEPS) wurde untersucht, ob sich ein vergleichbares Muster auch für das konsekutive Masterstudium zeigt. Die Analysestichprobe umfasste 95 Studierende der Wirtschaftswissenschaften, die zum Ende ihres Bachelorstudiums einen fachspezifischen Kompetenztest bearbeiteten und ein Masterstudium aufnahmen. Der Test zeigte eine mittelhohe Validität (unkorrigiertes $r = -.30$) bezüglich der Masternoten zwei Jahre später. Eine inkrementelle Validität über Hochschulzugangsberechtigungsnoten und Bachelornoten hinaus zeigte sich ebenso wenig wie eine geschlechtsspezifische differenzielle Prognose. Die Ergebnisse sprechen dafür, dass fachliche Fähigkeitstests aufgrund ihrer prädiktiven Validität für die Auswahl im Masterstudium geeignet sind, die durch die Bologna-Reform zur Herausforderung für Studieninteressierte wie auch Hochschulen geworden ist.

Schlüsselwörter: Studierfähigkeitstest, Validität, Wirtschaftswissenschaften, Studienerfolg, Geschlecht, differenzielle Prognose

Ready for Bologna? Test-based and Grade-based Prediction of Success in Master Studies

Abstract

Subject-specific competence tests have been proven to be valid predictors of academic success in Bachelor studies; such tests are therefore useful tools in student selection procedures. Using data from the National Educational Panel Study (NEPS), we investigated whether the pattern is similar for academic success in subsequent Master studies. The analysis sample consisted of 95 economics students who took a subject-specific competence test at the end of their Bachelor degree and began a subsequent Master. The test showed a medium-sized validity (uncorrected $r = -.30$) regarding the Master grade point averages (GPAs) two years later. There was no incremental validity over high school GPAs and Bachelor GPAs. Neither did we find sex-specific differential prediction. The results suggest that, due to their predictive validity, subject-specific competence tests are a suitable instrument for Master student selection, a process that the Bologna reform has turned into a challenge for applying students as well as for universities.

Keywords: admission test, validity, economics, academic performance, sex, differential prediction

Bereit für Bologna? Test- und notenbasierte Erfolgsprognose im Masterstudium

1 Einleitung

Die Vergabe von Studienplätzen bewegt sich im Spannungsfeld zwischen Bestenauslese und Chancenfairness. Im Zuge der Bologna-Reform betreffen Zulassungsverfahren neben dem Erststudium auch die neu eingeführten Masterstudiengänge. Denn weder in der Konzeption, noch in der Praxis gibt es so viele Masterstudienplätze wie es (interessierte) Bachelorabsolventinnen und -absolventen gibt (Kultusministerkonferenz, 2011). Die Instrumente, die für die Studierendenauswahl eingesetzt werden, sollen dabei in erster Linie prognostisch valide sein, also den zukünftigen Studienerfolg möglichst gut vorhersagen. Aber auch Kriterien wie die Kosten und die Logistik des Auswahlprozesses und die Anfälligkeit für Verfälschungen müssen berücksichtigt werden.

Während die Vorhersage des Studienerfolgs im Bachelor bereits vielfach untersucht wurde (z. B. Buschhüter, Spoden & Borowski, 2017; Fischer, Schult & Hell, 2015; Formazin, Schroeders, Köller, Wilhelm & Westmeyer, 2011; Hell, Linsner & Kurz, 2008), gibt es zur prognostischen Validität von Auswahlkriterien für das konsekutive Masterstudium kaum Forschungsbefunde aus dem deutschen Hochschulbetrieb. Entsprechend finden sich für das Masterstudium auch keine gesicherten Befunde zu Gruppenunterschieden bei der Leistungsprognose bezogen auf Personenmerkmale wie Geschlecht. In der vorliegenden Studie wird deshalb die prognostische Validität eines wirtschaftswissenschaftlichen Kompetenztests hinsichtlich des Studienerfolgs im Masterstudium untersucht. Im Fokus stehen dabei die operationale Validität der Testleistung, die inkrementelle Validität des Tests über bisherige Noten hinaus sowie die geschlechtsspezifische differenzielle Prognose.

1.1 Studienerfolgsprognose

Studienerfolg umfasst viele, häufig miteinander verbundene Aspekte. Dazu gehören ein erfolgreicher Abschluss, subjektive Zufriedenheit, berufliche Chancen und nicht zuletzt gute Noten (Stemler, 2012). Studiennoten kommt dabei eine besondere Bedeutung in der Validitätsforschung zu, da sie mit den anderen genannten Erfolgsindikatoren positiv zusammenhängen und bereits während des laufenden Studiums unkompliziert und fortlaufend erfasst werden können (Hell, Trapmann & Schuler, 2008; Strahan & Credé, 2015). Die Unschärfe des Konstrukts Studienerfolg spiegelt sich in den diagnostischen Verfahren zur Studierendenauswahl wider.

Studierfähigkeit ist ebenfalls ein diffuses Konstrukt, das sowohl kognitive wie auch motivationale Aspekte beinhaltet. Präziser dürften die Bezeichnungen Studieneignung oder Erfolgspotenzial sein (Stemler, 2012). Die Güte eines Auswahlinstruments wird in erster Linie durch seine Vorhersagekraft bestimmt. Die prädiktive Validität steht also deutlich im Vordergrund. Noten von bisherigen Schul- und Studienleistungen eignen sich in diesem

Sinne sehr gut als Prädiktoren, auch wenn sie eigentlich bereits erbrachte Bildungsleistungen bewerten (Schuler & Schult, 2018). Für die Durchschnittsnote der Hochschulzugangsberechtigung (HZB) zeigt sich in der metaanalytischen Übersicht dabei eine höhere Validität bei der Studienerfolgsprognose im Grundstudium/Bachelor ($r = .34$, $k = 10$, $n = 1568$) als im Hauptstudium/Master ($r = .25$, $k = 3$, $n = 504$; Trapmann, Hell, Weigand & Schuler, 2007). Ebenso können Bachelorabschlussnoten gut den Studienerfolg im Masterstudium vorhersagen. Für Psychologie-Studierende an der Universität Bern korrelierten die Bachelor- und die Masterabschlussnoten mit $r = .58$ ($p < .001$, $n = 256$), wobei sich keine inkrementelle Validität der HZB-Noten zeigte (Troche, Mosimann & Rammsayer, 2014). Noten, die von verschiedenen Institutionen vergeben wurden, sind allerdings nur bedingt vergleichbar. In diesem Sinne entschied das Bundesverfassungsgericht (BVG) zuletzt auch, dass die Hochschulen Studienplätze „nicht allein und auch nicht ganz überwiegend nach dem Kriterium der Abiturnoten“ vergeben dürfen (Bundesverfassungsgericht, 2017, Abs. 209). Hinzu kommt, dass etwa 40% der Studierenden für das Masterstudium die Hochschule wechseln (Bericht der Bundesregierung, 2015). Die Vergleichbarkeit von Bachelornoten aus verschiedenen Hochschulen und verschiedenen Fächern kann also auch bei der Masterstudienplatzvergabe problematisch werden, alleine schon angesichts von Benotungsunterschieden zwischen Universitäten und Fachhochschulen (Weimar, Schauburger, Borowski & Prinz, 2017). Als standardisiertes Auswahlinstrument, dessen Ergebnisse ein hohes Maß an Vergleichbarkeit bieten, werden deshalb oft fachspezifische Studierfähigkeitstests eingesetzt.

Studierfähigkeitstests spielen eine wichtige Rolle bei der Studierendenauswahl, gerade in stark nachgefragten Fächern wie Medizin (Schwibbe et al., 2018), Psychologie (Janke & Dickhäuser, 2018) und Wirtschaftswissenschaften (Weimar et al., 2017). Die Testverfahren sollen meist kognitive Kompetenzen erfassen.¹ Diese Kompetenzen können fachbezogen (z. B. ökonomisches Problemlösen), studiumsbezogen (z. B. wissenschaftliches Schreiben) wie auch allgemein gefasst sein (z. B. numerisches Schlussfolgern). Fachspezifische Studierfähigkeitstests decken dabei Intelligenzfacetten üblicherweise soweit ab, dass Intelligenz keine inkrementelle prognostische Validität mehr zeigt (Schult, Fischer & Hell, 2016). Einen Überblick über die prognostische Validität von fachspezifischen Studierfähigkeitstests im deutschsprachigen Raum bietet die Metaanalyse von Hell, Trapmann und Schuler (2007). Die höchste Validität zeigen Tests im Studiengang Humanmedizin mit $p = .51$ (korrigiert für Kriteriumsunreliabilität und Variabilitätseinschränkung; $k = 9$, $n = 34,438$). In wirtschaftswissenschaftlichen

¹ Es gibt weitere valide nichtkognitive Prädiktoren (z.B. Gewissenhaftigkeit; vgl. Schneider & Preckel, 2017; Schuler & Schult, 2018). Auswahlverfahren – und entsprechend auch der vorliegende Artikel – fokussieren aber überwiegend auf kognitive Prädiktoren, weil deren Messung weniger anfällig gegenüber bewussten Verfälschungen ist.

Studiengängen fiel die Validität niedriger aus mit $p = .33$ ($k = 7$, $n = 441$), wobei zu erwähnen ist, dass für Humanmedizin ausschließlich hochschulübergreifende Studien vorlagen, während in den Wirtschaftswissenschaften lediglich Stichproben von jeweils einer Hochschule untersucht worden waren (Hell et al., 2007). Die Validitätsunterschiede zwischen den Fächern sind möglicherweise ein Artefakt von homogeneren und entsprechend varianzärmeren Stichproben. Für die Erfolgsprognose im Masterstudium zeigt sich in internationalen Studien ein ähnliches Bild (vgl. Kuncel & Hezlett, 2007). Im deutschsprachigen Raum findet sich für den Masterbereich bislang nur eine Studie, obgleich im Rahmen der Bologna-Reform viele Hochschulen Studierfähigkeitstest zur Masterstudierendenauswahl einsetzen (vgl. Borowski, Schauburger & Weimar 2018).

Erste Validitätshinweise gibt eine Untersuchung mit $n = 841$ Masterabsolventinnen und -absolventen der Betriebs- und Volkswirtschaftslehre (aus zwei verschiedenen Universitäten), die im Rahmen des Zulassungsverfahrens den fachspezifischen Studierfähigkeitstest TM-WISO (Test für Masterstudiengänge in Wirtschafts- und Sozialwissenschaften)² bearbeitet hatten. Die Korrelation zwischen Testleistung und Masterabschlussnote betrug (unkorrigiert) $r = -.37$ (Stegt & Bergholz, in Begutachtung). In der vorliegenden Studie wird nun untersucht, ob sich diese Befunde auf einen anderen wirtschaftswissenschaftlichen Fähigkeitstest und Studierende von mehreren verschiedenen Hochschulen übertragen lassen. Angesichts des oben genannten BVG-Urteils und der bereits gängigen Auswahlpraxis scheint es zudem angezeigt, die inkrementelle Validität der Testleistung über die Bachelorabschlussnote hinaus zu betrachten.

1.2 Testfairness bei der Vorhersage des Studienerfolgs

Ein wichtiger Aspekt der Testfairness im Auswahlkontext ist die unverzerrte Erfolgsvorhersage (vgl. AERA, APA & NCME, 1999). Eine Vorhersage wird dann als fair angesehen, wenn für verschiedene Personengruppen dasselbe (lineare Regressions-)Modell für die Prognose verwendet werden kann. Eine Verzerrung liegt hingegen dann vor, wenn Personen aus verschiedenen Gruppen bei gleicher Testleistung unterschiedlich gut im Studium abschneiden (vgl. Fischer, Schult & Hell, 2013). Im Fokus stehen häufig Geschlechtsunterschiede. Für den Studienfeldbezogenen Beratungstest Wirtschaftswissenschaften zeigte sich bei der Vorhersage der Noten im Bachelor-Studium nach einem Jahr eine Unterschätzung der Leistung der Frauen ($n = 356$; Fischer et al., 2015). In der Regression von der Leistung in einem Masterzulassungstest auf die Bachelornote zeigte sich dagegen bei $n = 506$ BWL-Studierenden kein

² Der Test bestand aus den Teilen „Planen in Studium und Beruf“, „Texte analysieren“, „Wirtschaftliche Zusammenhänge formalisieren“ und „Wirtschaftsgrafiken interpretieren“ mit jeweils 18 gewerteten Multiple-Choice-Aufgaben. Die Testungen fanden computerbasiert unter Aufsicht statt. Die Bearbeitungszeit betrug 3:50 Stunden. Die Reliabilität des TM-WISO betrug $r = .87$ (Stegt & Bergholz, in Begutachtung).

Geschlechtsunterschied (Weimar et al., 2017). Dies deckt sich mit den metaanalytischen Befunden zum U.S.-amerikanischen GRE (Graduate Record Examination), für den sich kein bedeutsamer Geschlechtsunterschied bei der Vorhersage des Studienerfolgs zeigt: Bei gleicher GRE-Leistung schneiden Frauen im Studium lediglich um durchschnittlich 0.03 Standardabweichungen besser ab ($k = 13$, $n = 2,589$, $p = .96$; Fischer et al., 2013). Wie weit sich im deutschsprachigen Raum Geschlechtsunterschiede bei der Vorhersage des Masterstudienerfolgs durch Testleistungen zeigen, ist bislang unklar und gehört ebenfalls zu den Forschungsfragen, die nachfolgend mit Hilfe des Nationalen Bildungspanels (NEPS) untersucht werden.

1.3 Hypothesen

Der fachspezifische Kompetenztest ist valide bezüglich der Noten im Masterstudium (H1). Weiterhin besitzt er eine inkrementelle Validität über die HZB-Note (H2a), über die Bachelorabschlussnote (H2b) sowie über die HZB- und Bachelornote (H2c) hinaus. Außerdem wird die geschlechtsspezifische Fairness der Vorhersage exploriert (H3).

2 Methode

2.1 Stichprobe und Studiendesign

Diese Arbeit nutzt Daten des NEPS (Startkohorte 5: Studierende³). Diese Startkohorte bestand aus $N = 18,252$ Studienanfängerinnen und -anfängern, die im Wintersemester 2010/11 in Deutschland ihr Studium aufnahmen (vgl. Blossfeld, Roßbach & von Maurice, 2011; Steinwede & Aust, 2012). Die vorliegende Studie basiert dabei auf der Teilstichprobe der Studierenden, die a) 2014 den wirtschaftswissenschaftlichen Kompetenztest bearbeitet haben⁴, b) zum Testzeitpunkt ein wirtschaftswissenschaftliches Bachelorstudium machten (oder bereits abgeschlossen hatten) und c) anschließend ein Masterstudium begannen. Die finale Analysestichprobe umfasste $n = 95$ Personen (Geburtsjahr: $M = 1989$, $SD = 2.3$).

Als Prädiktorvariablen wurden die HZB-Note, die Bachelorabschlussnote sowie die Kompetenztestleistung verwendet. Die HZB-Note wurde beim Paneleintritt erfragt zusammen mit demografischen Angaben wie Geschlecht und Alter. Die erreichten Durchschnitts- und Abschlussnoten im Studium wurden laufend in weiteren Befragungswellen erhoben. Die Kompetenztestung fand im ersten Quartal 2014 statt. Die Mehrheit der Studierenden in der

³ doi:10.5157/NEPS:SC5:11.0.0. Die Daten des NEPS wurden von 2008 bis 2013 als Teil des Rahmenprogramms zur Förderung der empirischen Bildungsforschung erhoben, welches vom Bundesministerium für Bildung und Forschung (BMBF) finanziert wurde. Seit 2014 wird NEPS vom Leibniz-Institut für Bildungsverläufe e.V. (LIfBi) an der Otto-Friedrich-Universität Bamberg in Kooperation mit einem deutschlandweiten Netzwerk weitergeführt.

⁴ Aus den 1701 potenziellen Fällen wurden durch die Ziehung von 15 regionalen Clustern 601 Personen für die Kompetenztestung ausgewählt. Es konnten 342 Testungen realisiert werden, von denen 338 auswertbare Ergebnisse lieferten (Lauterbach, 2015).

Analysестichprobe hatte kurz zuvor ihren Bachelorabschluss erworben (Bachelorabschluss 2013: 54 %, Bachelorabschluss 2014: 36 %, Bachelorabschluss 2015: 10 %).

Als Erfolgskriterium wurde die Durchschnittsnote im Masterstudium zum Wintersemester 2015/16 verwendet oder, wenn diese nicht vorlag, die Durchschnittsnote zum Sommersemester 2014. Für Studierende, die bereits den Masterabschluss hatten, wurde analog die Abschlussnote verwendet ($n = 38$). Die Erhebung der Variablen im Zeitverlauf wird in Abbildung 1 schematisch illustriert. Die durchschnittliche Zeit zwischen dem Kompetenztest und der Kriteriumsleistung betrug im Schnitt $M = 2.0$ Jahre ($SD = 0.5$ Jahre).

Abbildung 1. Zeitschiene der verwendeten Erhebungszeitpunkte im Studienverlauf (HZB = Hochschulzugangsberechtigung)

2.2 Instrumente

Der wirtschaftswissenschaftliche Kompetenztest basiert auf übersetzten und adaptierten Aufgaben des mexikanischen EGEL (Exámenes Generales de Egreso de la Licenciatura; Centro Nacional de Evaluación para la Educación Superior, 2011) und des U.S.-amerikanischen TUCE (Test of Understanding in College Economics; Walstad, 2007). Die Tests erfassen für das Studium relevante Lerninhalte. Im Rahmen von Vorstudien und Expertenratings wurden 36 Aufgaben ausgewählt, die die Bereiche Marketing, Organisation, Finanzierung, Rechnungswesen, Mikroökonomie und Makroökonomie mit jeweils sechs Multiple-Choice-Aufgaben abdecken. Die papierbasierten Einzeltestungen wurden durch eine Interviewerin bzw. einen Interviewer administriert. Die Bearbeitungszeit betrug im Schnitt 42 Minuten ($SD = 6.9$ Minuten). Nach Ausschluss von zwei Items wegen differential item functioning (DIF) wurden die verbleibenden 34 Aufgaben Rasch-skaliert. Gewichtete Likelihood-Schätzungen (weighted likelihood estimates, WLE; Warm, 1989) wurden als Personenparameter als Schätzungen der Kompetenz der Studierenden verwendet ($M = 0$, $SD = 0.88$, $n = 338$). Die WLE-Reliabilität lag bei .77 (Details zur Entwicklung, Durchführung und Skalierung des Tests siehe Lauterbach, 2015).

2.3 Auswertungsplan

Zur Bestimmung der Validität der einzelnen Prädiktorvariablen hinsichtlich der Studienleistung im Master wurden bivariate Korrelationskoeffizienten berechnet (H1). Die operative Validität wurde durch die Korrelation nach der Korrektur für die Unreliabilität des Kriteriums (nicht aber des Prädiktors) sowie für restriction of range geschätzt. Als Kriteriumsreliabilität der Masternoten wurde $r = .93$ angenommen (Beatty, Sackett, Kuncel & Koch, 2015).

Die inkrementelle Validität wurde mit einer Reihe von linearen Regressionen zur Vorhersage der Masterstudienleistung bestimmt. Im ersten Schritt wurde die HZB-Note als Prädiktor verwendet. Anschließend wurden HZB-Note und Testleistung als Prädiktoren verwendet und der Zuwachs an erklärter Varianz (ΔR^2) auf Signifikanz getestet (H2a). Weiterhin wurde die inkrementelle Varianz der Testleistung über die Prädiktion durch die Bachelorabschlussnote (H2b) sowie über die Prädiktion durch HZB- und Bachelornote hinaus geprüft (H2c). Die Prädiktorvariablen gingen zentriert in die Regressionen ein.

Die differenzielle Prognose wurde mit einer moderierten multiplen Regression getestet (Cleary-Modell, vgl. Cleary, 1968; Fischer et al., 2013). Neben der Testleistung als Prädiktor wurde das Geschlecht (männlich = 0, weiblich = 1) sowie der dazugehörige Interaktionsterm mit aufgenommen (H3). Die Testleistung wurde auch für diese Regression zentriert, um die Interpretation des Intercepts als Gruppenunterschied bei mittlerem Leistungsniveau zu ermöglichen. Der Interaktionsterm und der Gruppenfaktor schätzen in solchen Modellen die gruppenspezifische Verzerrung bei der Studienerfolgsprognose.

Für das Datenmanagement und die Auswertung wurde Stata 13.1 verwendet. Als Signifikanzniveau wurde $\alpha = .05$ gewählt.

3 Ergebnisse

Die deskriptive Statistik der interessierenden Variablen wird zusammen mit den dazugehörigen Korrelationen in Tabelle 1 aufgelistet. Die Korrelation zwischen Testleistung und Masternotenschnitt betrug $r = -.30$ ($p = .003$). Das negative Vorzeichen des Validitätskoeffizienten ergibt sich dadurch, dass höhere Testwerte stärkere Leistungen anzeigen, während bei den Noten niedrigere Werte ein besseres Abschneiden angeben. Der Effekt bleibt auch nach der Korrektur für restriction of range⁵ und für die Kriteriumsreliabilität mittelgroß mit einer operativen Validität von $p = -.33$.

⁵ Tatsächlich führte die Korrektur für restriction of range zu einer leichten Validitätsverringern, da die Streuung der Testwerte in der Gesamttestung ($SD = 0.88$) etwas kleiner ausfiel als in der Analysestichprobe ($SD = 0.91$).

Tabelle 1

Bivariate Korrelationen und deskriptive Statistiken der Variablen

	2.	3.	4.	5.	<i>n</i>	<i>M</i>	<i>SD</i>
1. HZB-Note	.60*	-.37*	.45*	-.07	84	2.21	0.58
2. Bachelornote		-.42*	.57*	-.23*	94	2.11	0.46
3. Testleistung (WLE)			-.30*	-.25*	95	0.42	0.91
4. Masternote				-.01	95	1.90	0.41
5. Geschlecht (weiblich)					95	0.53	0.50

HZB = Hochschulzugangsberechtigung, WLE = weighted likelihood estimation
 * $p < .05$

Die Bachelorabschlussnote ($r = .57$) und die HZB-Note ($r = .45$) waren ebenfalls valide Prädiktoren des Studienerfolgs (jeweils $p < .001$). Es zeigte sich keine signifikante inkrementelle Validität des wirtschaftswissenschaftlichen Kompetenztests über die HZB-Note ($\Delta R^2 = .02$, $F(1, 81) = 2.06$, $p = .15$) bzw. über die Bachelorabschlussnote hinaus ($\Delta R^2 = .00$, $F(1, 92) = 0.54$, $p = .46$). Der Zuwachs an erklärter Varianz war nahe Null, wenn zuvor die Bachelor- und die HZB-Note als Prädiktor verwendet wurden ($\Delta R^2 = .00$, $F(1, 80) = 0.05$, $p = .83$; vgl. Tab. 2).

Tabelle 2

Lineare Regressionen zur Vorhersage der Masternote zur Überprüfung der inkrementellen Validität der Testleistung

Modell	H2a ($n = 84$)		H2b ($n = 94$)		H2c ($n = 84$)	
Prädiktor	<i>b</i> (SE)	β	<i>b</i> (SE)	β	<i>b</i> (SE)	β
Intercept	1.91* (0.04)		1.90* (0.03)		1.91* (0.04)	
HZB-Note ^{zen}	0.33* (0.07)	0.45			0.10 (0.08)	0.14
Bachelornote ^{zen}			0.50* (0.07)	0.57	0.47* (0.10)	0.51
R^2	.20*		.33*		.37*	
Intercept	1.91* (0.04)		1.90* (0.03)		1.91* (0.04)	
HZB-Note ^{zen}	0.29* (0.08)	0.40			0.10 (0.08)	0.14
Bachelornote ^{zen}			0.48* (0.08)	0.54	0.46* (0.11)	0.51
Testleistung ^{zen}	-0.07 (0.05)	-0.15	-0.03 (0.04)	-0.07	-0.01 (0.05)	-0.02
R^2	.22*		.33*		.37*	
ΔR^2	.02		.00		.00	

HZB = Hochschulzugangsberechtigung, ^{zen} = Variable wurde zentriert.

* $p < .05$

Bei der Exploration der differenziellen Prognose gab es keine geschlechtsspezifische Verzerrung. Die Regressionsgeraden zur Vorhersage der Masternoten sind in Abbildung 2 getrennt für Frauen und Männer dargestellt. Weder die beiden Steigungen ($p = .89$), noch die beiden geschlechtsspezifischen Intercepts unterschieden sich signifikant ($p = .39$; vgl. Tab. 3). Das geringfügig bessere Abschneiden der Frauen bei gleicher Testleistung ($\Delta b = -0.07$ Notenpunkte) kann also nicht generalisiert werden.

Tabelle 3

Moderierte multiple Regression zur Vorhersage der Masternote gemäß Cleary (1968) mit Test auf gleiche Steigungen (Interaktionsterm) und gleiche Intercepts (Geschlechtsterm)

Modell	H3
Prädiktor	b (SE)
Intercept	1.94* (0.06)
Testleistung ^{zen}	-0.15* (0.06)
Geschlecht (männlich = 0, weiblich = 1)	-0.07 (0.08)
Testleistung ^{zen} × Geschlecht	0.01 (0.10)
R^2	.10*

$n = 95$, ^{zen} = Variable wurde zentriert.

* $p < .05$

Abbildung 2. Geschlechtsspezifische Regressionsgeraden zur Prognose der Masternoten durch die Kompetenztestleistung. Die Geraden sind für die Spannweite der jeweiligen Testleistungen eingezeichnet.

4 Diskussion

Anhand der Studierenden-Kohorte des NEPS wurde untersucht, welche prognostische Validität ein wirtschaftswissenschaftlicher Kompetenztest hinsichtlich des Erfolgs im Masterstudium aufweist. Die Testleistung, die kurz vor bzw. nach Ende des Bachelorstudiums erhoben wurde, korrelierte mittelhoch mit den Noten im Masterstudium. Der Test ist somit ähnlich valide wie wirtschaftswissenschaftliche Studierfähigkeitstests im Bachelor/Grundstudium (vgl. Hell et al., 2007). Aufgrund der fortgeschrittenen Studienerfahrung im Master sowie der möglichen Selbstselektion der Studierenden wäre es auch denkbar gewesen, dass ein Kompetenztest keine Studienleistungsvarianz mehr erklärt. Die Testleistungen der analysierten Masterstichprobe streuten zwar nicht mehr als die aller getesteten Studierenden; sie waren im Mittel jedoch (numerisch) besser ($\Delta = 0.42$, vgl. Tab. 1). Da die untersuchte Stichprobe aus Studierenden verschiedener deutscher Hochschulen besteht (die aus Datenschutzgründen leider nicht identifiziert und abgezählt werden können), ergänzen die vorliegenden Befunde hochschulspezifische Studien (z.B. Stegt & Bergholz, in Begutachtung). Fachspezifische Tests sind entsprechend bereit für Bologna und ein hilfreiches Instrument für die Auswahl von Masterstudierenden.

Eine inkrementelle Validität der Kompetenztestleistung über die Bachelor- und HZB-Noten hinaus konnte hingegen nicht gefunden werden. Die hohen Interkorrelationen zwischen den Prädiktorvariablen deuten darauf hin, dass überlappende kognitive Fähigkeiten von den Noten und dem Test erfasst werden. Weiterhin war der eingesetzte Test kürzer als übliche Studierfähigkeitstests (vgl. z. B. 72 gewertete TM-WISO-Items bei Stegt & Bergholz, in Begutachtung) und fokussierte stärker auf Kenntnisse als auf kognitive Fähigkeiten. Die hohe Korrelation zwischen den Bachelornoten und den Testwerten deutet auf eine Nähe der Testinhalte zum Bachelorlernstoff hin. Der Kompetenztest hatte zudem keine Auswahlfunktion, so dass die Studierenden im Gegensatz zu Zulassungstests und Prüfungen im Studium anders motiviert waren.

Der Geschlechtsunterschied bei der Vorhersage fiel sehr klein aus, so dass in dieser Hinsicht von einer fairen Prognose der Studienleistung durch den Kompetenztest gesprochen werden kann. Dieses Ergebnis deckt sich mit den internationalen metaanalytischen Befunden (Fischer et al., 2013). Ein weiterer wichtiger Fairness-Aspekt ist DIF, also der Gruppenunterschied bei den Schwierigkeiten einzelner Aufgaben. Der hier verwendete Test wurde bereits bei der Erstellung auf Geschlechts-DIF untersucht, wobei sich keine Probleme zeigten (Lauterbach, 2015). Für zukünftige Studien größerer Kohorten wäre die Fairness in Abhängigkeit des Migrationshintergrunds zu untersuchen, da sich hier in den Wirtschaftswissenschaften teils deutliche Testleistungsunterschiede zeigen (Happ, Förster & Beck, 2018). Breiter gefasst bleibt außerdem die Frage, wie weit die Kosten für die

Teilnahme an Zulassungsverfahren sozio-ökonomisch schwache Personen möglicherweise von vornherein von einem weiterführenden Studium abschrecken.

4.1 Limitationen

Obwohl es sich beim NEPS um eine äußerst umfangreich angelegte Panelerhebung handelt, ist der Umfang der Analysestichprobe nicht ausreichend für weiterführende Analysen. Bei der Auswertung wurden zwangsläufig Studierende in sehr unterschiedlichen Situationen zusammengefasst, um eine hinreichende Teststärke zu bekommen. Beispielsweise kann ein standardisiertes Testverfahren im Masterstudium besonders für Studierende valide sein, die für den Master die Hochschule wechseln und somit Bachelorabschlüsse von unterschiedlichen Hochschulen mitbringen (vgl. allerdings Nulleffekte bei Troche et al., 2014). Während die Vergleichbarkeit von HZB-Noten und Bachelorabschlüssen – gerade auch bei Studierenden aus dem Ausland – eine Herausforderung sein kann, bieten Studierfähigkeitstests hier eine transparente Vergleichsmöglichkeit.

Die vorliegende Studie beschränkt sich auf eine Fachrichtung und dort auf einen Kompetenztest. Die Übertragbarkeit der Befunde auf andere Fächer ist nicht unbedingt gegeben. Wenn sich U.S.-amerikanische Befunde übertragen lassen, dürfte die prädiktive Validität in anderen Fächern tendenziell größer ausfallen (vgl. Kuncel & Hezlett, 2007).

Als Erfolgskriterium wurden ausschließlich Noten betrachtet. Weitere Dimensionen von Studienerfolg sind u.a. Erreichen des Studienabschlusses (bzw. entgegengesetzt Studienabbruch), Studienzufriedenheit, Studiendauer und anschließender Berufserfolg (vgl. Stemler, 2012). Der Bologna-Prozess hat nicht zuletzt durch die Aufteilung des Studiums in Bachelor und Master, die beide stark auf quantifizierte Leistungsnachweise fokussieren, die erreichten Noten jedoch in den Vordergrund gerückt. Somit sind diese auch aus Hochschulsicht ein wichtiger Kennwert.

Wie bereits erwähnt handelte es sich bei der Kompetenztestung nicht um eine Auswahl-situation. Im Gegensatz zu zentralen Zulassungstestungen wurden die Studierenden einzeln von geschulten Interviewern getestet. Die unterschiedliche Situation (Einzel- statt Gruppentestung) sollte jedoch nebensächlich sein, da sich zumindest bei Intelligenztests kein Setting-Unterschied zeigt (Becker, Koch, Schult & Spinath, 2017).

4.2 Fazit

Da es zur Validität von Auswahlverfahren für Masterstudiengänge im deutschsprachigen Raum bislang kaum empirische Untersuchung gibt, liefert die vorliegende Studie wichtige Erkenntnisse für Hochschulen, die fachspezifische Kompetenztests einsetzen bzw. einsetzen wollen. Der wirtschaftswissenschaftliche Kompetenztest, der im NEPS eingesetzt wird (Lauterbach, 2015), besitzt prognostische Validität hinsichtlich der Studienleistung im Master. Die Vorhersagekraft fällt dabei ähnlich hoch aus wie die mittlere Validität für fachspezifische Studierfähigkeitstests in den Wirtschaftswissenschaften (vgl. die Metaanalyse von Hell et al.,

2007). Anhand der NEPS-Daten konnte also gezeigt werden, dass Tests fachlicher Kompetenzen auch in konsekutiven Masterstudiengängen eine valide Erfolgsprognose liefern und somit als Instrument für die Studierendenauswahl geeignet sind.

Literatur

- American Educational Research Association [AERA], American Psychological Association [APA] & National Council on Measurement in Education [NCME]. (1999). *Standards for educational and psychological testing* (4th ed.). Washington, DC: American Educational Research Association.
- Beatty, A. S., Walmsley, P. T., Sackett, P. R., Kuncel, N. R. & Koch, A. J. (2015). The reliability of college grades. *Educational Measurement: Issues and Practice*, 34(4), 31–40. doi:10.1111/emip.12096
- Becker, N., Koch, M., Schult, J. & Spinath, F. M. (2017). Setting doesn't matter much: A meta-analytic comparison of the results of intelligence tests obtained in group and individual settings. *European Journal of Psychological Assessment*. doi:10.1027/1015-5759/a000402
- Blossfeld, H.-P., Roßbach, H.-G. & von Maurice, J. (Hrsg.) (2011). Education as a Lifelong Process – The German National Educational Panel Study (NEPS). *Zeitschrift für Erziehungswissenschaft: Sonderheft 14*.
- Bericht der Bundesregierung (2015). *Umsetzung des Bologna-Prozesses 2012–2015 in Deutschland*. Zugriff am 29.10.2018
https://www.bmbf.de/files/Bericht_der_Bundesregierung_zur_Umsetzung_des_Bologna-Prozesses_2012-2015.pdf
- Borowski, S.; Schauburger, M. & Weimar, D. (2018). Zugangs- und Zulassungsvoraussetzungen an deutschen Hochschulen: Eine deskriptive Bestandsaufnahme. *Hochschulmanagement*, 13(2), 41–48.
- Bundesverfassungsgericht (2017). Urteil des Ersten Senats vom 19. Dezember 2017 – 1 BvL 3/14 – Rn. (1 – 253), Zugriff am 11.10.2018
http://www.bverfg.de/e/ls20171219_1bvl000314.html
- Buschhüter, D., Spoden, C. & Borowski, A. (2017). Studienerfolg im Physikstudium: Inkrementelle Validität physikalischen Fachwissens und physikalischer Kompetenz. *Zeitschrift für Didaktik der Naturwissenschaften*, 23, 127–141. doi:10.1007/s40573-017-0062-7
- Centro Nacional de Evaluación para la Educación Superior (2011). *Exámenes Generales para el Egreso de la Licenciatura*. Mexico City: DF.
- Cleary, T. A. (1968). Prediction of grades of negro and white students in integrated colleges. *Journal of Educational Measurement*, 5, 115–124. doi:10.1111/j.1745-3984.1968.tb00613.x

- Fischer, F. T., Schult, J. & Hell, B. (2013). Sex-specific differential prediction of college admission tests: A meta-analysis. *Journal of Educational Psychology*, 105, 478–488. doi:10.1037/a0031956
- Fischer, F., Schult, J. & Hell, B. (2015). Unterschätzung der Studienleistungen von Frauen durch Studierfähigkeitstests: Erklärbar durch Persönlichkeitseigenschaften? *Diagnostica*, 61, 34–46. doi:10.1026/0012-1924/a000120
- Formazin, M., Schroeders, U., Köller, O., Wilhelm, O. & Westmeyer, H. (2011). Studierendenauswahl im Fach Psychologie. *Psychologische Rundschau*, 62, 221–236. doi:10.1026/0033-3042/a000093
- Happ, R., Förster, M. & Beck, K. (2018). Eingangsvoraussetzungen von Studierenden der Wirtschaftswissenschaften mit und ohne Migrationshintergrund. *Zeitschrift für empirische Hochschulforschung*, 2(1), 6–22. doi:10.3224/zehf.v2i1.01
- Hell, B., Linsner, M. & Kurz, G. (2008). Prognose des Studienerfolgs. In M. Rentschler & H.-P. Voss (Hrsg.), *Studieneignung und Studierendenauswahl – Untersuchungen und Erfahrungsberichte* (S. 132–177). Aachen: Shaker
- Hell, B., Trapmann, S. & Schuler, H. (2007). Eine Metaanalyse der Validität von fachspezifischen Studierfähigkeitstests im deutschsprachigen Raum. *Empirische Pädagogik*, 21, 251–270.
- Hell, B., Trapmann, S. & Schuler, H. (2008). Synopse der Hohenheimer Metaanalysen zur Prognostizierbarkeit des Studienerfolgs und Implikationen für die Auswahl- und Beratungspraxis. In H. Schuler & B. Hell (Hrsg.), *Studierendenauswahl und Studienentscheidung* (S. 43–54). Göttingen: Hogrefe.
- Janke, S. & Dickhäuser, O. (2018). Zur prognostischen Güte von Zulassungskriterien im Psychologiestudium für Studienerfolgsindikatoren. *Psychologische Rundschau*, 69, 160–168. doi:10.1026/0033-3042/a000383
- Kultusministerkonferenz (2011). *Situation im Masterbereich und statistische Erfassung von Masterstudienplätzen: Eine Diskussionsgrundlage*. Beschluss der Kultusministerkonferenz vom 29.04.2011.
- Kuncel, N. R. & Hezlett, S. A. (2007). Standardized tests predict graduate students' success. *Science*, 315, 1080–1081. doi:10.1126/science.1136618
- Lauterbach, O. (2015). *Erfassung wirtschaftswissenschaftlicher Fachkompetenzen von Studierenden in Startkohorte 5 des Nationalen Bildungspanels – Technischer Bericht* (Aktualisierung NEPS Working Paper No. 51). Bamberg: Leibniz-Institut für Bildungsverläufe, Nationales Bildungspanel.
- Schneider, M. & Preckel, F. (2017). Variables associated with achievement in higher education: A systematic review of meta-analyses. *Psychological Bulletin*, 143, 565–600.

- Schuler, H. & Schult, J. (2018). Prädiktoren von Studien- und Berufserfolg. In D. H. Rost, J. R. Sparfeldt & S. R. Buch (Hrsg.), *Handwörterbuch Pädagogische Psychologie* (5. Aufl., S. 645–653). Weinheim: Beltz.
- Schult, J., Fischer, F. T. & Hell, B. (2016). Tests of scholastic aptitude cover reasoning facets sufficiently. *European Journal of Psychological Assessment*, 32, 215–219. doi:10.1027/1015-5759/a000247
- Schwibbe, A., Lackamp, J., Knorr, M., Hissbach, J., Kadmon, M. & Hampe, W. (2018). Medizinstudierendenauswahl in Deutschland. *Bundesgesundheitsblatt – Gesundheitsforschung – Gesundheitsschutz*, 61, 178–186. doi:10.1007/s00103-017-2670-2
- Stegt, S. & Bergholz, L. (in Begutachtung). Vorhersage des Studienerfolgs in konsekutiven Masterstudiengängen mithilfe eines kognitiven Eignungstests.
- Steinwede, J. & Aust, F. (2012). *NEPS Startkohorte 5 – CATI-Haupterhebung Herbst 2010 B52 (Methodenbericht)*. Bonn: infas.
- Stemler, S. E. (2012). What should university admissions tests predict? *Educational Psychologist*, 47, 5–17. doi:10.1080/00461520.2011.611444
- Strahan, S. & Credé, M. (2015). Satisfaction with college: Re-examining its structure and its relationships with the intent to remain in college and academic performance. *Journal of College Student Retention: Research, Theory & Practice*, 16(4), 537–561. doi:10.2190/CS.16.4.d
- Trapmann, S., Hell, B., Weigand, S. & Schuler, H. (2007). Die Validität von Schulnoten zur Vorhersage des Studienerfolgs – eine Metaanalyse. *Zeitschrift für Pädagogische Psychologie*, 21, 11–27. doi:10.1024/1010-0652.21.1.11
- Troche, S., Mosimann, M. & Rammsayer, T. (2014). Die Vorhersage des Studienerfolgs im Masterstudiengang Psychologie durch Schul- und Bachelorstudienleistungen. *Beiträge zur Hochschulforschung*, 36(1), 30–45.
- Walstad, W. B. (2007). *Test of Understanding in College Economics*. New York: National Council on Economic Education.
- Walstad, W. B., Rebeck, K. & Butters, R. B. (2013). *Test of Economic Literacy: Examiner's manual* (4th ed). New York: Council for Economic Education.
- Warm, T.A. (1989) Weighted likelihood estimation of ability in item response theory. *Psychometrika*, 54, 427–450. doi:10.1007/BF02294627
- Weimar, D., Schauburger, M., Borowski, S. & Prinz, J. (2017). Selektionseffekte von Zulassungstests an Universitäten. *Betriebswirtschaftliche Forschung und Praxis*, 69, 694–716.