

DARSTELLUNG VON KOMPETENZUNTERSCHIEDEN IN DER BILDUNGSBERICHTERSTATTUNG

Ulrich Ludewig¹

¹Institut für Schulentwicklungsforschung, Technische Universität Dortmund, Vo-
gelpothsweg 78, 44227 Dortmund,  <https://orcid.org/0000-0001-9614-847X>

ulrich.ludewig@tu-dortmund.de

1 Einleitung

International Large Scale Assessments (ILSA), wie Progress In International Reading Literacy Study (PIRLS/IGLU), Programme for International Student Assessment (PISA) und Trends In International Mathematics And Science Study (TIMSS) sind dazu ausgelegt mittlere Kompetenzunterschiede zwischen Kohorten eines Staates (Trends) über Jahre hinweg und zwischen Staaten in einem Jahr (Ländervergleiche), sowie Kompetenzunterschiede zwischen Schülergruppen (Disparitäten) zu beschreiben. Trends, Ländervergleiche und Disparitäten sind häufig von großem bildungspolitischen und gesellschaftlichen Interesse. Die Kommunikation von Kompetenzunterschieden an die Öffentlichkeit und an Praktizierende im Bildungswesen ist eine wichtige Aufgabe der empirischen Bildungsforschung (Baumert & Tillmann, 2020). Kompetenzunterschiede werden mit Hilfe von Einheiten oder „Punkten“ auf einer abstrakten und studienspezifischen Skala ausgedrückt. Die *Bedeutung* von Unterschieden auf diesen Skalen ist nicht immer intuitiv ersichtlich und besonders, wenn Studienergebnisse auf zentrale Ergebnisse reduziert werden müssen, kann die Umwandlung der Erkenntnisse in allgemeinverständliche Aussagen eine Herausforderung sein (Rauch & Hartig, 2020). Berichtslegungen, die die praktische Bedeutung von Kompetenzunterschieden nicht gut kommunizieren, werden von der Öffentlichkeit und von Praktizierenden im Bildungswesen übersehen oder missverstanden und verfehlen damit einen Teil ihrer Zielsetzung. In diesem Beitrag wird beschrieben, wie sich die Bedeutung von Kompetenzunterschieden mit Hilfe von alternativen Darstellungsformen (Lipsey et al., 2012) und Benchmarkvergleichen (Brunner et al., 2022; Hill et al., 2001) kommunizieren lassen.

Kompetenzunterschiede können als (a) statistisch signifikant qualifiziert, (b) mit einer bestimmten statistischen Größe quantifiziert und (c) als praktisch bedeutend eingeordnet werden. Es ist wichtig diese drei Aspekte: statistische Signifikanz, statistische Größe und Bedeutung klar voneinander zu unterscheiden, um Ergebnisse wissenschaftlich korrekt und verständlich darzustellen. (a) Statistisch signifikant bedeutet, dass ein Ergebnis mit geringer Wahrscheinlichkeit durch Zufall entstanden ist. Statistische Signifikanz wird an einem Schwellenwert festgelegt

und qualifiziert einen Unterschied entweder als nachweisbar oder als nicht nachweisbar. Die Bedeutung von *statistisch signifikant*: überzufällig, nachweisbar oder interpretierbar unterscheidet sich damit von der alltagsprachlichen Bedeutung von *signifikant*: bedeutend, erheblich oder relevant. (b) Eine statistische Größe quantifiziert einen Unterschied mit einer bestimmten Maßeinheit. In ILSAs sind die Maßeinheiten, die „Punkte“ (d.h. Anteile der Standardabweichung) auf der jeweiligen Skala. Die Punkte stehen in keinem notwendigen Verhältnis zur statistischen Signifikanz. Es kann relativ große Punktunterschiede geben, die bei geringer Präzision der Schätzungen nicht statistisch signifikant sind und kleine Punktunterschiede geben, die auf Grund von hoch präzisen Schätzungen statistisch signifikant sind. In ILSAs sind Stichproben häufig so groß, dass auch kleine Unterschiede mit hoher Wahrscheinlichkeit statistisch signifikant sind. (c) Als bedeutend können Kompetenzunterschiede eingeordnet werden, wenn sie statistisch signifikant sind und ihre statistische Größe in Beziehung zu Vorwissen, lebensweltlichen Erfahrungen und bekannten Ergebnissen stehen. Die statistische Größe des Kompetenzunterschiedes steht in keinem notwendigen Verhältnis zur Bedeutung von Kompetenzunterschieden (Lipsey et al., 2012). Statistisch gesehen kleine Unterschiede zwischen Schülerkohorten können zum Beispiel bedeutend sein, weil auch ein geringfügiges Absinken von Leistungen in einer gesamten Schülerkohorte einen Einfluss auf den weiteren Bildungserfolg oder die Erwerbstätigkeit im Lebensverlauf haben kann (Hanushek et al., 2017). Ein Kompetenzunterschied mit vergleichbarer statistischer Größe zwischen Gymnasien und nicht-Gymnasien kann weniger bedeutend sein, weil Schüler:innen ohnehin unter anderem auf Grund von leistungsbezogenen Merkmalen auf Gymnasien oder nicht-Gymnasien aufgeteilt werden. Somit gehören zur Beschreibung von Kompetenzunterschieden immer Aussagen über die statistische Signifikanz, die statistische Größen und zur Bedeutung der statistischen Größe im Kontext.

Die statistische Größe von Kompetenzunterschieden werden in ILSAs als Einheiten einer Standardabweichung oder „Punkte“ auf einer normierten Skala dargestellt. Eine normierte Skala stellt Testwerte als Abstand zum Mittelwert einer Referenzgruppe dar. Der Mittelwert der Referenzgruppe wird dabei auf 500 und ihre Standardabweichung auf 100 festgelegt. Ein Punkt auf der Skala, entspricht einem Hundertstel einer Standardabweichung in der Referenzgruppe (Rauch & Hartig,

2020). Zum Beispiel in PIRLS/IGLU besteht die Referenzgruppe aus Schüler:innen, die 2001 an der Studie teilgenommen haben. Ein Punkt auf der IGLU-Skala ist also ein hundertstel einer Standardabweichung in der Referenzgruppe der 22 Staaten und Regionen, die 2001 an der IGLU-Studie teilgenommen haben. Die Referenzgruppen unterscheiden sich zwischen verschiedenen ILSA Studien, weshalb Punktunterschiede zwischen Studien nicht direkt verglichen werden können. Die Verwendung von Skala stellt sicher, dass Kompetenzunterschiede zwischen Ländern in einer Erhebung, eines Landes zwischen Erhebungen und zwischen Schülergruppen statistisch korrekt abbilden sind. Gleichzeitig sind Punkte auf den ILSA Skalen dadurch aber für sich genommen abstrakte statistische Größen, die nicht intuitiv interpretierbar sind. Kompetenzunterschiede können in weniger abstrakte alternative Darstellungen umgewandelt werden, die Prozente als Einheiten verwenden. Durch diese Umwandlung verlieren die Kompetenzunterschied aber auch immer einen Teil ihrer statistischen Eigenschaften (siehe Kapitel 2).

Kompetenzunterschiede lassen sich unabhängig von ihrer Skala in die Effektstärke d überführen und damit zwischen Studien vergleichen (siehe z.B. Ludewig, Kleinkorres et al., 2022). Cohen's- d ist ein Maßstab für die Effektstärke, der verwendet wird, um den Unterschied zwischen zwei Normalverteilungen auszudrücken (Cohen, 1988). Es wird berechnet, indem der Unterschied zwischen den beiden Mittelwerten durch die gepoolte (d.h. auf besondere Weise gemittelt) Standardabweichung der Gruppen geteilt wird. Eine Einheit von Cohen's- d entspricht einer gepoolten Standardabweichung und ist für sich betrachtet ebenfalls eine abstrakte und nicht intuitiv interpretierbare Einheit. Cohen hat im Jahr 1988 vorgeschlagen bei Unterschieden von circa $d = 0.2$ von kleinen, von $d = 0.5$ von mittleren und von $d = 0.8$ von großen Effekten zu sprechen. Diese Konvention hat ihren Nutzen darin, dass sie den Werten 0.2, 0.5, und 0.8 den Begriffen klein, mittel und groß zuordnet, steht aber in keinem notwendigen Zusammenhang mit praktischer Bedeutung.

Um die praktische Bedeutung von Kompetenzunterschieden hervorzuheben können Kompetenzunterschiede mit Hilfe von Cohen's- d zwischen Studien miteinander verglichen werden. Besonders informative Vergleiche sind Ergebnisse aus bekannten Befunden oder Ergebnisse mit einem lebensweltlichen Bezug, den sogenannten „Benchmarks“ (siehe Kapitel 3). Zur Illustration der alternativen Darstel-

lungsformen (siehe Kapitel 2) und Benchmarkvergleiche (Kapitel 3) beschreiben wir den Unterschied zwischen dem Höchststand der Lesekompetenz bei Viertklässler:innen 2006 ($M = 548$, $SD = 67$) und niedrigsten Stand 2021 ($M = 524$, $SD = 77$; Frey et al., 2021).

2 Alternative Darstellungen von Kompetenzunterschieden

2.1 Perzentilunterschiede

Kompetenzunterschiede können auch als Perzentile dargestellt werden. Ein Perzentil beschreibt an welchem Abschnitt Schüler:innen liegen, wenn man alle Schüler:innen in einer geordneten Liste aufführen und diese Liste in 100 gleich große Abschnitte aufteilen würde. Das Perzentil bezeichnet den Abschnitt in dem Schüler:innen mit einem bestimmten Wert liegen. Ein Schüler/eine Schülerin, der/die sich auf dem 25. Perzentil befindet, ist besser als 25 % und schlechter als 75 % der Schüler:innen. Perzentile können verwendet werden, um den Wert einzelner Schüler:innen zu beschreiben, aber auch, um den Unterschied zwischen zwei Verteilungen zu beschreiben. Dafür wird die Differenz zwischen dem Perzentil der Mittelwerte, basierend auf ihren Perzentilen in der Referenzgruppe berechnet. Die Angabe von Perzentilunterschieden wird häufig als nützlicher bewertet als Einheiten einer Standardabweichung, weil die Prozentangaben beschreiben (Lipsey et al., 2021). Der Lesekompetenzmittelwert der Viertklässler:innen 2006 lag 9 % höher in der Referenzgruppe als 2021 (siehe Abbildung 1).

2.2 Anteil unter einer inhaltlich begründeten Schwelle

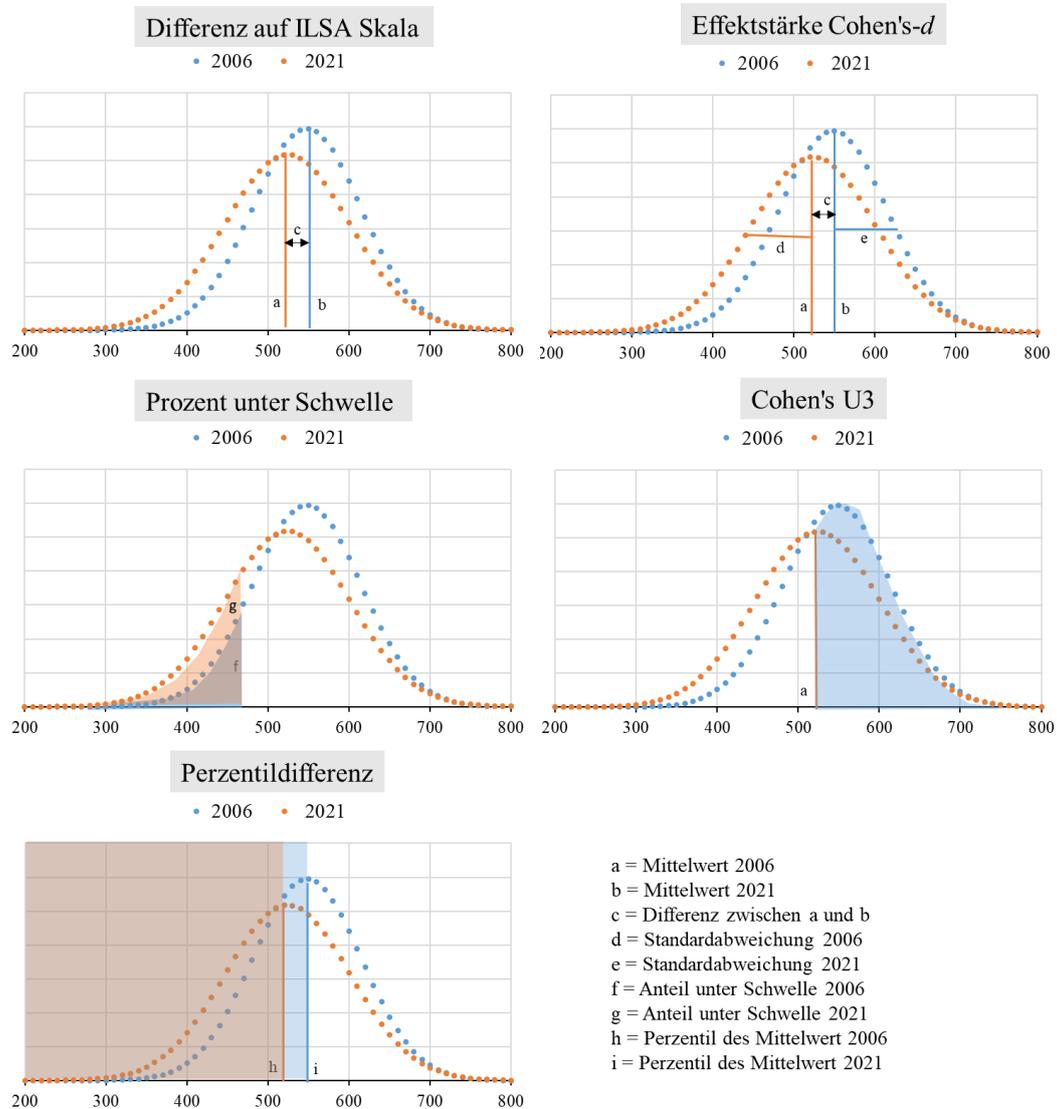
Ein weiterer Ansatz besteht darin, einen informativen Schwellenwert auf der Normverteilung zu wählen und den Kompetenzunterschied mit dem Anteil zu beschreiben mit dem die Gruppen unter (oder über) diesen Wert fallen (siehe z.B. Ludewig, Schlitter et al., 2022). In ILSA Studien können die Schwellenwerte von Kompetenzstufenmodellen verwendet werden (Rauch & Hartig, 2020). Für die IGLU/PIRLS Studie 2021, ist der untere Schwellenwert der Kompetenzstufe III 475 Punkte. Die Kompetenzstufe III gilt auch als internationaler Mindeststandard für die Lesekompetenz am Ende der vierten Klasse. Angewandt bedeutet, diese so erreichen, 14 % der Schüler:innen 2006 und 26 % der Schüler:innen 2021 nicht den internationalen Mindeststandard für die Lesekompetenz in der vierten Klasse erreichen (geht man von einer perfekten Normalverteilung aus). Des Wei-

teren kann hieraus geschlossen werden, dass die Kinder 2021 12 % Prozentpunkte häufiger und damit ein fast doppelt höheres relatives Risiko haben, die Mindeststandards nicht zu erreichen.

2.3 Anteil unter einer statistischen Schwelle

Es gibt auch die Möglichkeit die Anteile einer Verteilung unter (oder über) einem statistisch definierten Schwellenwert zu berichten. Cohen (1988) beispielsweise verwendete den Mittelwert der Gruppe mit dem geringeren Mittelwert als allgemeinen Schwellenwert, um einen Index zu erstellen, den er U3 nannte. Der Unterschied zwischen Kindern 2006 und 2021 hat einen U3 von 64 %. Das bedeutet, dass 64 % der Schüler:innen 2006 eine Lesekompetenz haben, die über dem Mittelwert der Schüler:innen 2021 liegt.

Abbildung 1. Darstellung der verschiedenen Darstellungsformen von Kompetenzunterschieden am Beispiel des Lesekompetenzunterschieds zwischen Viertklässler:innen 2006 und 2021.



3 Benchmarks

3.1 Klassische Befunde

Vergleiche mit Effektstärken aus bekannten und klassischen Befunden können die Einordnung von Studienergebnissen erleichtern. Die Befunde der ILSA Studie PISA im Jahr 2000 wurden als Weckruf wahrgenommen. Ein häufig berichteter Unterschied war der zwischen Deutschland ($M = 484$, $SD = 111$) und Finnland ($M = 546$, $SD = 89$), was dazu führte, dass das skandinavische Bildungssystem als vorbildlich galt und gilt. Dieser Unterschied entspricht einer Effektstärke von $d = 0.62$.

Zusätzlich könnte man noch Ergebnisse anführen, die vielen Rezipienten von Bildungsberichterstattungen bekannt sein könnten. Der Lesekompetenzunterschied zwischen Schüler:innen an Gymnasien ($M = 578$, $SD = 76$) und nicht-Gymnasien 2018 ($M = 458$, $SD = 93$) beträgt $d = 1.41$ (PISA, 2018). Der Unterschied zwischen Jungen ($M = 532$, $SD = 78$) und Mädchen ($M = 543$, $SD = 78$) in der Lesekompetenz 2016 beträgt $d = 0.14$ (IGLU, 2016).

Ein weiteres relevantes Ergebnis ist die größte Differenz, die empirisch auf einer ILSA Skala erfasst wurde. Hier lässt sich der Unterschied zwischen dem Staat mit dem besten und dem schlechtesten Lesekompetenzergebnis bei PISA 2018 anführen, zwischen China's Beijing, Shanghai, Jiangsu und Zhejiang ($M = 555$, $SD = 87$) und der Dominikanischen Republik ($M = 336$, $SD = 71$) mit $d = 2.77$.

3.2 Mittlerer Leistungszuwachs

Die durchschnittliche akademische Leistungsentwicklung von Schüler:innen (Hill et al., 2008) bietet eine weitere wichtige Vergleichsmöglichkeit. Die Leistungen der Schüler:innen sind das Ergebnis langfristiger, kumulativer bereichsspezifischer Prozesse des Erwerbs von Wissen und Fähigkeiten (z.B. Baumert et al., 2009). Leistungszuwächse unterscheiden sich zwischen Domänen, zwischen Klassenstufen und unterliegen auch saisonalen Schwankungen (Lee et al., 2018). Der Lesekompetenzzuwachs von der dritten auf die vierte Klassenstufe wird auf

$d = 0.40$ (Hill et al., 2008) oder $d = 0.29$ (Ditton & Krüskens, 2009) geschätzt. Von der siebten auf die achte Klasse führen Hill et al. (2008), $d = 0.26$ und Brunner et al. (2022) $d = 0.15$ an.

3.3 Mittlerer Leistungszuwachs durch Förderung

Eine weitere Vergleichsmöglichkeit sind die Effekte von Leseförderprogrammen. Unterschiede können also im Vergleich dazu eingeordnet werden, was ein Leseförderprogramm bewirken könnte. In einer Metaanalyse von Gersten et al. (2020) haben Leseförderprogramme für das Lesen von Wörtern, das Leseverständnis und das flüssige Lesen von Textpassagen am Ende der Grundschule eine mittlere Effektgröße von $d = 0.39$. Hall und Burns (2018) fanden für Kleingruppen-Leseinterventionen einen Gesamteffekt von $g^l = 0.54$.

3.4 Lernjahräquivalente

Durchschnittliche Lernjahrzuwächse lassen sich auch dafür nutzen Lernjahräquivalente zu berechnen. Das bedeutet, der Effekt der corona-bedingten Einschränkungen ($d = -0.18$) kann ins Verhältnis zum durchschnittlichen Leistungszuwachs eines Jahres gesetzt werden ($d = -0.39$). Das bedeutet, dass der Effekt der corona-bedingten Einschränkungen dem entspricht, was durchschnittlich in einem halben Jahr gelernt wird (Ludewig, Lorenz et al., 2022).

Baird und Pane (2019) kritisieren die Berechnungen von Lernjahräquivalenten aus verschiedenen Gründen. Lernjahräquivalente laden dazu ein, dass Rezipierende falsche Interpretationen vornehmen: Die Schüler:innen müssten ein halbes Jahr länger zur Schule gehen, um den Rückstand aufzuholen. Der durchschnittliche Leistungszuwachs beschreibt wie viel Schüler:innen normalerweise Lernen, was Reifungsprozesse, außerschulisches und schulisches Lernen beinhaltet. Damit bietet die Umrechnung des Effekts von corona-bedingten Einschränkungen in Lernjahre keine solide Grundlage für Rückschlüsse darauf, wie zusätzliche Unterrichtstage die Ergebnisse beeinflussen würden. Darüber hinaus wird die statistische Unsicherheit in der Regel ignoriert, obwohl die Übersetzung die Unsicher-

¹ $g = \text{Hedge's } g$. Cohens d und Hedges g sind hinsichtlich ihrer Interpretation identisch, basieren aber auf unterschiedlichen Berechnungsgrundlagen. Hedge's g hat vorteilhafte Eigenschaften bei sehr unterschiedlich großen Stichproben.

heit gegenüber der ursprünglichen Schätzung des Unterschiedes oft erheblich erhöht.

Tabelle 1. Darstellung von Effektstärken zwischen 2.27 und 0.14.

	China vs. Dom. Republik (8. Klasse)	Finnland vs. Deutschland (8. Klasse)	Drittkläss- ler:innen vs. Viertkläss- ler:innen	2006 vs. 2021 (4.Klasse)	Mädchen vs. Jungen (4. Klasse)
Quelle	PISA 2018	PISA 2000	Hill et al., 2008	IGLU 2021	IGLU 2016
Norm					
M	500	500	0	500	500
SD	100	100	1	100	100
Gruppen					
M_1	555	546	0.4	548	543
M_2	336	484	0	524	532
SD_1	87	89	1	67	78
SD_2	71	111	1	77	78
Punkte Δ	219	62	0.4	24	11
Cohen's- d	2.58	0.57	0.40	0.35	0.14
Cohen's- $U3$	100%	71%	66%	64%	56%
Benchmark Ler- njahr (d)	0.26	0.26	0.40	0.40	0.40
Lernmonate Δ	119	26	12	11	4
Perzentil ₁	71	68	66	68	67
Perzentil ₂	5	44	50	59	63
Perzentil Δ	66	24	16	9	4
Begründete Schwelle	408	408	-1	475	475
< Schwelle ₁	5%	6%	8%	14%	19%
< Schwelle ₂	84%	25%	16%	26%	23%
Prozentpunkte Δ	80%	19%	8%	12%	4%
Relatives Risiko	18.5	4.1	2.0	1.9	1.2

4 Zusammenfassung

Die Vermittlung der Bedeutung von Kompetenzunterschieden ist eine wichtige Aufgabe der Bildungsberichterstattung zu ILSA Studien. Die Bedeutung von Kompetenzunterschieden kann weder von der statistischen Signifikanz noch aus der statistischen Größe der Unterschiede abgeleitet werden. Die Bedeutung von Kompetenzunterschieden muss durch die Verknüpfung mit anderen Informationen oder dem Vorwissen des Rezipierenden verdeutlicht werden. Für das Beispiel des Lesekompetenzunterschieds zwischen Viertklässler:innen 2006 und 2021 lassen sich folgende Aussagen generieren:

- Der Lesekompetenzunterschied zwischen Viertklässler:innen 2006 und 2021 entspricht 24 Punkten auf der IGLU-Skala und einer standardisierten Effektstärke von $d = 0.35$.
- Die Effektstärke von $d = 0.35$ wird nach Cohen als ein Effekt mit mittlerer bis kleiner Stärke beschrieben.
- Der Lesekompetenzunterschied zwischen Kindern 2006 und 2021 ist...
 - ... deutlich kleiner als der zwischen Gymnasien und nicht-Gymnasien in der achten Klasse, sowie dem Unterschied zwischen Deutschland und Finnland in PISA 2000.
 - ... etwa so groß wie der durchschnittliche Lernzuwachs innerhalb des vierten Schuljahres, sowie so groß wie der durchschnittliche Lernzuwachs durch eine gezielte Lesefördermaßnahme.
 - ... deutlich größer als der Unterschied zwischen Jungen und Mädchen in der vierten Klasse.
- Der Lesekompetenzunterschied bedeutet, dass Viertklässler:innen 2006 denen 2021 um 9 % voraus sind.
- Etwa 64 % der Viertklässler:innen 2006 haben eine höhere Lesekompetenz als durchschnittliche Viertklässler:innen 2021.

- Schüler:innen 2021 haben eine um 12 % höhere Wahrscheinlichkeit die Mindeststandards für Lesekompetenz der vierten Klasse nicht zu erreichen, als Schüler:innen 2006.
- Die Mindeststandards werden von Schüler:innen 2021 mit einer doppelt so hohen relativen Wahrscheinlichkeit unterschritten wie von Schüler:innen 2006.
- Der Lesekompetenzunterschied zwischen Viertklässler:innen 2006 und 2021 ist etwa so bedeutend, wie der Lesekompetenzzuwachs von einem Schuljahr.

Differenzen in Punkten einer ILSA eignen sich sehr gut dafür Kompetenzunterschiede innerhalb einer Studie zu vergleichen. Die Punkte auf der ILSA Skala sind aber für sich betrachtet schwierig zu interpretieren. Die Einheiten der Effektstärke d sind ebenfalls nicht ohne Weiteres interpretierbar. Jedoch lassen sich Effektstärken dafür nutzen, um Ergebnisse zwischen Studien zu vergleichen. Zwei Möglichkeiten Differenzen in Prozentenwerten darzustellen sind Cohen's U_3 und Perzentildifferenzen. Während Cohen's U_3 sich direkt aus der Effektstärke ergibt, benötigen Perzentildifferenzen eine Normreferenzierung. Durch die Normreferenzierung von Perzentildifferenzen können zwei identische Effektstärken unterschiedlichen Perzentildifferenzen entsprechen.

Wenn es eine inhaltlich begründete Schwelle gibt, können Prozentpunktdifferenzen zwischen den Anteilen beider Gruppen berechnet werden, die unter dem Schwellenwert liegen. Prozentpunktdifferenzen an Schwellenwerten sind unterschiedlich, je nachdem wo die Schwellen gesetzt werden und ergeben im Vergleich zu Perzentildifferenzen und Cohen's U_3 numerisch kleine Werte. Alternativ zu Prozentpunktdifferenzen kann das relative Risiko berichtet werden. Das relative Risiko kann zu Fehlinterpretationen führen, wenn die Anteile, die eine Gruppe unterscheiden, sehr gering sind. Wie die Skalen sind auch Schwellenwerte in der Regel studienspezifisch, daher sollten Prozentpunktdifferenzen und relative Risiken nicht ohne Weiteres zwischen Studien verglichen werden.

Die verschiedenen Darstellungsformen können dafür genutzt werden, Unterschiede, deren Bedeutung wichtig ist, mit anderen Ergebnissen zu vergleichen, zum Beispiel mit bereits bekannten Studien, dem durchschnittlichen Lernzuwachs ei-

nes Jahres, dem durchschnittlichen Effekt von Fördermaßnahmen oder einem besonderen Ereignis. Wie hilfreich der Vergleich jeweils ist, hängt stark davon ab, ob es passende Vergleichsgrößen gibt, die mit hinreichender Präzision zur Verfügung stehen. Lernjähreäquivalente sind besonders eindrücklich (Lortie-Forgues et al., 2021), es sollte aber deutlich gemacht werden, dass es darum geht die Bedeutung einzuordnen und nicht um eine genaue Bestimmung von z.B. Unterrichtsbedarfen. Zu dem eignen sich Lernjähreäquivalente nicht mehr in höheren Klassenstufen, weil dort jährliche Lernzuwächse sehr klein sind und sich so unplausible höhere Lernjahrdifferenzen ergeben können. Zum Beispiel ergibt die Differenz zwischen China und der Dominikanische Republik einen Unterschied von 119 Lernmonaten bzw. etwa 10 Jahren. Da die Schüler:innen in beiden Ländern noch nicht 10 Jahre zur Schule gegangen sind, ist das Ergebnis unplausibel (Tabelle 1, graues Feld).

5 Literatur

- Baird, M. D., & Pane, J. F. (2019). Translating standardized effects of education programs into more interpretable metrics. *Educational Researcher*, 48(4), 217-228.
- Baumert, J., & Tillmann, K.-J. (Eds.). (2016). *Empirische Bildungsforschung: Der kritische Blick und die Antwort auf die Kritiker*. Wiesbaden: Springer VS.
- Baumert, J., Lüdtke, O., Trautwein, U., & Brunner, M. (2009). Large-scale student assessment studies measure the results of processes of knowledge acquisition: Evidence in support of the distinction between intelligence and student achievement. *Educational Research Review*, 4, 165–176.
- Brunner, M., Stallasch, S. E., & Lüdtke, O. (2023). Empirical Benchmarks to Interpret Intervention Effects on Student Achievement in Elementary and Secondary School: Meta-Analytic Results from Germany. *Journal of Research on Educational Effectiveness*, 1-39.
- Cohen, J. (1988). *Statistical power analysis for the behavioral sciences* (2. Auflage). Hillsdale, NJ: Erlbaum.
- Ditton, H., & Krüsken, J. (2009). Denn wer hat, dem wird gegeben werden? Eine Längsschnittstudie zur Entwicklung schulischer Leistungen und den Effekten der sozialen Herkunft in der Grundschulzeit. *Journal for educational research online*, 1(1), 33-61.
- Frey, A., Ludewig, U., König, C., Krampen, D., Lorenz, R., & Bos, W. (2023). Lesekompetenz von Viertklässlerinnen und Viertklässlern im internationalen Vergleich: 20-Jahre-Trend. In *Lesekompetenz von Grundschulkindern im internationalen Vergleich und im Trend über 20 Jahre* (pp. 111–129). Waxmann.
- Gersten, R., Haymond, K., Newman-Gonchar, R., Dimino, J., & Jayanthi, M. (2020). Meta-analysis of the impact of reading interventions for students in the primary grades. *Journal of Research on Educational Effectiveness*, 13(2), 401-427.
- Gersten, R., Haymond, K., Newman-Gonchar, R., Dimino, J., & Jayanthi, M. (2020). Meta-analysis of the impact of reading interventions for students in the primary grades. *Journal of Research on Educational Effectiveness*, 13(2), 401-427.
- Hall, M. S., & Burns, M. K. (2018). Meta-analysis of targeted small-group reading interventions. *Journal of School Psychology*, 66, 54-66.
- Hammerstein, S., König, C., Dreisörner, T., & Frey, A. (2021). Effects of COVID-19-related school closures on student achievement-a systematic review. *Frontiers in psychology*, 12, 746289.

- Hanushek, E. A., Schwerdt, G., Woessmann, L., & Zhang, L. (2017). General education, vocational education, and labor-market outcomes over the lifecycle. *Journal of human resources*, 52(1), 48-87.
- Hill, C. J., Bloom, H. S., Black, A. R., & Lipsey, M. W. (2008). Empirical benchmarks for interpreting effect sizes in research. *Child development perspectives*, 2(3), 172-177.
- Hußmann, A., Wendt, H., Bos, W., Bremerich-Vos, A., Kasper, D., Lankes, E. M., ... & Valtin, R. (Eds.). (2017). *IGLU 2016: Lesekompetenzen von Grundschulkindern in Deutschland im internationalen Vergleich*. Münster: Waxmann.
- Krüskens, J. Kapitel 2: Entwicklung von Schülerleistungen und Zensuren in der Grundschule. *Kompetenzaufbau und Laufbahnen im Schulsystem*, 41.
- Lee, J., Finn, J., & Liu, X. (2019). Time-indexed effect size for educational research and evaluation: Reinterpreting program effects and achievement gaps in K–12 reading and math. *The Journal of Experimental Education*, 87(2), 193-213.
- Lipsey, M. W., Puzio, K., Yun, C., Hebert, M. A., Steinka-Fry, K., Cole, M. W., ... & Busick, M. D. (2012). Translating the Statistical Representation of the Effects of Education Interventions into More Readily Interpretable Forms. *National Center for Special Education Research*.
- Lortie-Forgues, H., Sio, U. N., & Inglis, M. (2021). How Should Educational Effects Be Communicated to Teachers? *Educational Researcher*, 50(6), 345–354.
- Ludewig, U., Kleinkorres, R., Schaufelberger, R., Schlitter, T., Lorenz, R., König, C., Frey, A., & McElvany, N. (2022). COVID-19 Pandemic and Student Reading Achievement: Findings From a School Panel Study. *Frontiers in psychology*, 13, 876485.
- Ludewig, U., Lorenz, R., Kleinkorres, R., & McElvany, N. (2022). Sonderauswertung: Wortschatz und Leseverhalten bei Viertklässler:innen in Deutschland – Daten einer repräsentativen bundesweiten Studie. Dortmund: Technische Universität Dortmund, Institut für Schulentwicklungsforschung.
- Ludewig, U., Schlitter, T., Lorenz, R., Kleinkorres, R., Schaufelberger, R., Frey, A. & McElvany, N. (2022). Die COVID-19 Pandemie und Lesekompetenz von Viertklässler*innen. Ergebnisse der IFS-Schulpanelstudie 2016-2021. Dortmund: Technische Universität Dortmund, Institut für Schulentwicklungsforschung.
- Rauch, D., & Hartig, J. (2020). Interpretation von Testwerten in der Item-Response-Theorie (IRT). *Testtheorie und Fragebogenkonstruktion*, 411-424.