Marco Mundelius

Der Kerndatensatz auf der Basis von Individualdatenerhebungen in der Schulstatistik Von Summendaten zu Einzeldaten

Zusammenfassung

Die öffentliche Aufmerksamkeit für die Einführung von Individualdaten in der Schulstatistik hat in den vergangenen Jahren insgesamt etwas abgenommen; der „Kerndatensatz“ und die „Datengewinnungsstrategie“ der KMK stehen aber immer wieder und zu unterschiedlichen Zeitpunkten in den einzelnen Ländern im Fokus der Medien, der Wissenschaft und der Eltern. In diesem Beitrag wird nachgezeichnet, wie sich die KMK auf den Weg gemacht hat, mithilfe der Umstellung der Schulstatistik auf Individualdatensätze verbesserte Datengrundlagen für das notwendige bildungspolitische Steuerungswissen zu erhalten und dabei die Belange des Datenschutzes in vollem Umfang zu berücksichtigen.

Schlüsselwörter: Schulstatistik, Individualdatenerhebungen, Kerndatensatz

The Core Set of Data on the Basis of Individual Data Surveys in School Statistics

From Aggregated Data to Individual Data

Abstract

The public attention to the introduction of individual data in school statistics has slightly decreased in recent years; but the “core set of data” and the “data acquisition strategy” of the Standing Conference of the Ministers of Education and Cultural Affairs in the Länder of the Federal Republic of Germany (KMK) are time and again and at different points in time in the focus of the media, of science and of parents in the individual federal states. This contribution shows how the KMK has set out to get an improved database for the necessary education-political management knowledge by a conversion of the school statistics to individual data, while fully observing the concerns of data protection.

Keywords: school statistics, individual data survey, core set of data

Warum Individualdaten in der Schulstatistik?

Zur laufenden Information über relevante gesellschaftliche und strukturelle Entwicklungen im Bildungsbereich (Bildungsberichte, amtliche Statistiken), als Basis für Prognosen und Modellrechnungen, als Grundlage für die Entwicklung von politischen und administrativen Maßnahmen, als Informationsquelle über den Stand von Zielerreichungen (z. B. EU-Benchmarks) und zur Überprüfung der Wirksamkeit von bildungspolitischen Maßnahmen werden in den Ländern schulstatistische Daten im Rahmen von Vollerhebungen erfasst. Wissenschaftler*innen fordern seit langem eine erhebliche Verbesserung der Datenbasis für die genannten Zwecke; denn viele Fragen, die von großer politischer Relevanz sind, können mit statistischen Summendaten derzeit nur mit unverhältnismäßig hohem Aufwand (Zusatzerhebung an den Schulen) beantwortet werden. Die Lösung besteht in der Umstellung auf Einzeldaten, wie sie in vielen anderen Statistikbereichen bereits vollzogen ist. Auch können nur auf diesem Wege unterschiedliche Bildungsverläufe statistisch ohne Personenbezug analysiert werden. Beispiele hierzu wären der Vergleich des Schulerfolges von Kindern mit Migrationshintergrund im Großstadtbereich bzw. im ländlichen Raum mit dem von Kindern ohne einen Migrationshintergrund oder der Vergleich von Bildungskarrieren von Jungen und Mädchen. Ebenso könnten die langfristige Wirksamkeit des „Sitzensbleibens“ untersucht oder die Durchlässigkeit des Bildungssystems, besonderes an den „Schnittstellen“ und beim Übergang in die Ausbildung, unter Berücksichtigung des sozio-ökonomischen Hintergrundes der Schüler*innen überprüft werden. Das Nationale Bildungspanel (NEPS) stellt hier zwar eine Verbesserung der Datenlage dar, ist aber z. B. für die Bildungsberichterstattung nur bedingt nutzbar, da es aufgrund der zu kleinen Stichprobe keine Ergebnisse auf Länderebene bereitstellen kann.

Um solche Analysen ländervergleichend und deutschlandweit durchführen zu können, haben die Länder einen in Inhalt und Struktur einheitlichen Kerndatensatz vereinbart, der aus Individualdaten besteht. Die Individualdaten sollen aus regelmäßig durchgeführten Vollerhebungen mit über die Jahre hinweg konstanten Pseudonymen stammen, um schuljahresübergreifende Auswertungen zu ermöglichen. Dazu sollen die Daten ab der Einschulung anonym mit einer Identifikationsnummer, kurz „Schüler-ID“, gespeichert werden.

„Nach dem Grundgesetz liegt die Kulturhoheit bei den Ländern, die allerdings im Rahmen ihrer Zusammenarbeit in der Kultusministerkonferenz bemüht sind, eine abgestimmte Grundstruktur der Schulen in der Bundesrepublik zu sichern. Dennoch gibt es Unterschiede in den Voraussetzungen und kultuspolitischen Zielrichtungen, die teilweise zu unterschiedlichen Ausprägungen des Bildungswesens in den Ländern führen.“ (Schmittlein, 1990, S. 20)

Der lange Weg

Sowohl aufgrund der erhöhten Nachfrage nach schulstatistischen Daten für überregionale und internationale Zwecke als auch im Gefolge der PISA-Studie hat die Kultusministerkonferenz bereits im Jahr 2000 eine Neufassung des Katalogs überregional und international notwendiger schulstatistischer Daten, die in den Ländern einheitlich zu erheben sind (den so genannten „Minimalkatalog“), beschlossen. Aus dem Minimalkatalog wurde dann der so genannte „Kerndatensatz“ (KDS) abgeleitet. Der KDS beschreibt, welche Daten zu den Schüler*innen, zu den Absolvent*innen, zu den Lehrkräften, zu den Einrichtungen und zu den Unterrichtseinheiten in den Ländern für länderübergreifende Auswertungen vorliegen sollen.

Im Jahre 2003 beschloss dann die KMK die *Empfehlung zur Sicherstellung eines einheitlichen Aufkommens schulstatistischer Daten für überregionale Zwecke unter Berücksichtigung des Kerndatensatzes bei Umstellung der Schulstatistik von summarischen Daten auf Individualdaten*. Vereinbart wurde, die Umstellung auf Individualdatenerhebungen und die Umsetzung des Kerndatensatzes in der Schulstatistik bis 2008 in den Ländern zu erreichen.

Ferner betonte die KMK auf Initiative der sogenannten „Zöllner-AG“ im Juni 2005 die Notwendigkeit der Einführung von Individualdaten zur Sicherung der internationalen Anschlussfähigkeit der nationalen Daten im Bildungsbereich. Auf Initiative des damaligen Kultusministers des Landes Rheinland-Pfalz und internationalen Datenbeauftragten der KMK, Zöllner, wurden zusammen mit dem Bundesministerium für Bildung und Forschung (BMBF), dem Statistischen Bundesamt und Vertreter*innen der Landesministerien die Parameter und Indikatoren in der internationalen Bildungsberichterstattung gesichtet und ein Maßnahmenkatalog zur „Analyse der nationalen Datenlieferung für die internationale Bildungsberichterstattung“ erarbeitet.

Anfang 2007 stellte die KMK ihre Überlegungen in einem Workshop zur „Datengewinnungsstrategie für die Bildungsstatistik“ vor – einem Workshop, der nicht nur an die Vertreter*innen der Presse und Öffentlichkeit adressiert war, sondern auch als Plattform zum Austausch mit verantwortlichen Bildungspolitikern*innen, empirischen Bildungsforscher*innen und Datennutzer*innen dienen sollte. Ein halbes Jahr zuvor gelangte ein Arbeitsentwurf der Datengewinnungsstrategie der KMK an die Öffentlichkeit, noch bevor er beschlussreif war und die KMK mit den Datenschützer*innen in einen Dialog über die einzelnen Vorschläge hatte treten können. Viele der öffentlichen Missverständnisse, die in der Folge auftraten, sind vermutlich auf die vorzeitige Veröffentlichung dieses Entwurfs zurückzuführen.

Die vorzeitige öffentliche Erörterung des Themas hat auch dazu geführt, dass statistische Fachbegriffe nicht mehr in für die Allgemeinheit verständliche und ein-

deutige Begrifflichkeiten „übersetzt“ werden konnten. Ein Beispiel: Den beteiligten Expert*innen war immer klar, dass mit dem Merkmal „Wohnort des Schülers/der Schülerin“ nicht die genaue Wohnadresse gemeint ist. In der öffentlichen Diskussion wurden aber genau solche Befürchtungen geäußert. Der in der öffentlichen Diskussion und beim Workshop offensichtlich gewordene Bedarf an Informationen hat dann zur Erarbeitung und Veröffentlichung des Papiers *FAQ's – Frequently Asked Questions zum Kerndatensatz und zur Datengewinnungsstrategie* (KMK, 2008) geführt.

Wie sicher sind die Daten?

Der Umgang mit personenbezogenen oder personenbeziehbaren Informationen steht seit der Volkszählung 1987 in Deutschland unter Missbrauchsverdacht. Um dem entgegenzuwirken, hat die KMK die sogenannte Datengewinnungsstrategie und die Konzeption des „Kerndatensatzes für die Erhebung von Individualdaten“ entwickelt, die helfen sollen, die Öffentlichkeit zu informieren.

Zur Entfernung des Personenbezuges der Einzeldatensätze soll für den Kerndatensatz eine Einwegverschlüsselung nach einem ländereinheitlichen zweistufigen Verfahren genutzt werden. Auf der ersten Stufe soll eine Hash-Verschlüsselung des Datensatzes auf Landesebene oder bereits dezentral, z. B. in den Schulen, erfolgen. Auf der zweiten Stufe soll zur weiteren Erhöhung der Sicherheit gegen Entschlüsselungsangriffe eine zusätzliche Verschlüsselung des Hash-Wertes nach einem symmetrischen oder asymmetrischen Verschlüsselungsverfahren durch Integration eines Geheimnisses stattfinden. Diese zweite Verschlüsselung soll in den Ländern zentral erfolgen, um durch eine möglichst geringe Zahl von Verschlüsselungsstellen die praktische Wirksamkeit der Maßnahme sicherzustellen.

Für die Ermittlung des Hash-Wertes sollen wenig veränderliche Personenmerkmale der Schüler*innen verwendet werden: Geschlecht, Vorname, Nachname, Geburtsdatum und Geburtsort. Die Hash-Werte und das nach Integration des Geheimnisses entstehende Pseudonym sollen auf diese Weise über die Jahre weitgehend konstant bleiben. Da anhand der verwendeten Merkmale immer dasselbe Pseudonym erzeugt wird, könnte auf diese Weise auf eine sonst notwendige Datenübermittlung bei einem Umzug oder Schulwechsel verzichtet werden. Die personenbezogenen Merkmale, die zur Erzeugung der Hash-Werte notwendig sind, werden nach der Berechnung der Werte dauerhaft und vollständig aus dem Datensatz gelöscht. An keiner Stelle wird eine Tabelle mit einer Zuordnung zwischen personenidentifizierenden Merkmalen (Hash-Werten und Pseudonymen) abgelegt. Das geplante zweistufige Verschlüsselungsverfahren erlaubt einerseits statistische (!) Aussagen über Bildungsverläufe, schließt aber andererseits einen Rückbezug auf eine bestimmte Person nahezu aus, so dass von einer hochwertigen Pseudonymisierung der Datensätze gesprochen werden kann. Die auf diese Weise hochwertig pseudonymisierten

Einzeldaten sollen in den jeweiligen Ländern gespeichert werden. Entgegen ersten Überlegungen sollen die Daten nicht zu einem länderübergreifenden Datenbestand zusammengeführt werden.

Für länderübergreifende Auswertungen sollen ausschließlich die für die jeweilige Fragestellung benötigten Merkmale jeweils in Form schwach aggregierter Datensätze der mit der Auswertung beauftragten Stelle zur Verfügung gestellt werden. Auswertungen, die über das Veröffentlichungsprogramm der amtlichen Statistik oder Anforderungen internationaler Organisationen hinausgehen, sollen in den Gremien der KMK abgestimmt werden.

Bildungsforscher*innen sollen für spezielle Analysen sogenannte „scientific use files“ über die Forschungsdatenzentren der Statistischen Ämter zur Verfügung gestellt werden. Es wurde vereinbart, dass Abfragen, deren Ergebnis eine Reidentifizierung anhand spezieller Merkmale oder Bildungsverläufe möglich machen würde, grundsätzlich nicht veröffentlicht werden.

Die rechtlichen und organisatorischen Voraussetzungen für die Umsetzung des Konzeptes müssen in den einzelnen Ländern geschaffen werden. Dabei sind Fragen der technischen Realisierung gemäß der länderübergreifenden Vereinbarungen zu konkretisieren.

Abb. 1: Schematische Darstellung zur Nutzung schulstatistischer Einzeldaten mittels Merkmalsreduzierung

Quelle: Datengewinnungsstrategie der KMK (2006), unveröffentlicht.

Im Zuge der Abstimmung der Datengewinnungsstrategie der KMK mit der Konferenz der Datenschutzbeauftragten von Bund und Ländern im Jahr 2008 hat der damalige Vorsitzende der Konferenz, der Bundesdatenschutzbeauftragte Schaar, die im Konzept vorgesehene Einwegverschlüsselung nach einem ländereinheitlichen zweistufigen Verfahren sehr positiv bewertet.

Umsetzung in allen Ländern

Obwohl der Beschluss zur Umsetzung des Kerndatensatzes und zur Einführung von Individualdaten in der Schulstatistik einstimmig gefasst worden ist (bei Enthaltung Sachsens), ist er bis heute nicht vollständig umgesetzt. Zurzeit sind kaum Fortschritte erkennbar, und die Situation in den Ländern, in denen die Umsetzung noch aussteht, scheint zu stagnieren.

Für einen Bericht zur Umsetzung des Beschlusses haben bei einer Länderabfrage im Jahr 2018 einzelne Länder angegeben, die datenschutzrechtlichen Voraussetzungen zu erarbeiten. Als Gründe für die Stagnation werden aber auch fehlende Finanzmittel sowie der Widerstand der Eltern und Schulen ins Feld geführt. In einigen Ländern scheitert die Umstellung auch an dem fehlenden politischen Willen oder der fehlenden Einsicht in die Notwendigkeit einer Umstellung/Weiterentwicklung der amtlichen Schulstatistik. Es scheint, dass der Datenschutz zunehmend als „Ausstiegsklausel“ aus der Statistikmodernisierung genutzt wird. Schließlich unterliegt das föderale Schulsystem der Aufsicht der Landesdatenschützer*innen, weil eine Schülerdatenbank zunächst erst einmal Ländersache ist.

Auch wird, wenn auch selten, darauf verwiesen, dass es problematisch sei, auf Verwaltungsabläufe einzuwirken, wenn Individualdaten benutzt werden. Statt einer aufwendigen Individualstatistik würden die Bildungsplaner*innen mit Stichproben und Umfragen schneller das Ziel erreichen, die kommende Bildungsentwicklung zu erkennen.

Ausblick

Nach übereinstimmender Einschätzung der zuständigen Fachgremien und der Bildungswissenschaften kann der wachsende Datenbedarf für den Schulbereich mit dem bisherigen Anforderungskatalog von Daten in aggregierter Form nicht mehr erfüllt werden. Die geforderte und zwingend notwendige Flexibilität bei der Datenbereitstellung ist auf diesem Weg nicht zu erreichen. Es muss darauf hingewiesen werden, dass die amtliche Schulstatistik anderen Bildungsstatistiken im Vorschul-, Ausbildungs- und Hochschulbereich schon seit Jahren hinterherhinkt, insofern als in

diesen Bildungsbereichen auf bundesgesetzlicher Grundlage ein einheitliches Datenaufkommen sichergestellt ist.

Mit dem Beschluss zur Einführung des Kerndatensatzes ist auf KMK-Ebene Ähnliches auf dem Vereinbarungsweg versucht worden, aber bislang gescheitert: Ein Land hat sich von vornherein enthalten, einige Länder haben ihre Schulstatistiken umgestellt oder arbeiten daran, andere haben fünfzehn Jahre nach der Beschlussfassung nur geringe oder keine Fortschritte vorzuweisen. Selbst wenn die Umsetzung auf Länderebene komplett erfolgt wäre, würde nach wie vor noch die Klärung einer länderübergreifenden Zusammenführung der Daten ausstehen.

Zu den Hauptgründen für die Verzögerung der Umsetzung des KDS in der Schulstatistik zählen neben den Abstimmungen mit den Datenschutzbeauftragten der Länder die anfallenden Kosten für den Umstellungsprozess. Die Umstellung von summarischen auf Einzelfalldaten sowie die Herstellung der im Kerndatensatz geforderten Verknüpfungen zwischen den verschiedenen Merkmalsbereichen verursachen einen zusätzlichen finanziellen Mittelbedarf, vornehmlich für die Schaffung einer zeitgemäßen IT-Infrastruktur in den Schulen und den Schulaufsichtsbehörden. Die hierfür erforderlichen Investitionen lassen aber aus zwei Gründen vor allem im betreffenden Land eine Amortisation erwarten: Zum einen werden Schulen und Schulaufsichtsbehörden in die Lage versetzt, Verwaltungsabläufe effizienter als in der Vergangenheit zu gestalten; zum anderen entstehen durch die detailliertere Datenbasis Informations- und Erkenntnisgewinne, die eine verbesserte Planung und einen zielgenaueren Ressourceneinsatz ermöglichen. Zudem dürften sich die Kosten für die erforderliche Software durch Länder-Kooperationen deutlich senken lassen.

Es ist noch reichlich politische Überzeugungsarbeit nötig. Ob im Zuge des Projektes „Registerzensus“, welches organisatorisch im Statistischen Bundesamt verortet sein wird, ein neuer Impuls gegeben wird, bleibt abzuwarten. Dazu bedarf es wiederum der Unterstützung der jeweiligen Kultusbehörden.

Literatur und Internetquellen

KMK (Sekretariat der Ständigen Konferenz der Kultusminister der Länder in der Bundesrepublik Deutschland) (2008). *FAQ's – Frequently Asked Questions zum Kerndatensatz und zur Datengewinnungsstrategie*. Zugriff am 17.03.2019. Verfügbar unter: <https://www.kmk.org/dokumentation-statistik/statistik/schulstatistik/faqs-zum-kerndatensatz-und-zur-datengewinnungsstrategie.html>.

Schmittlein, K. (1990). Die Bildungsprognosen der Länder und der Kultusministerkonferenz – Methoden und Probleme. In C. Helberger & P. Palamidis (Hrsg.), *Diagnose und Prognose des Bildungsverhaltens* (S. 19–42). Baden-Baden: Nomos Verlagsgesellschaft.

Marco Mundelius, Dr., geb. 1968, Referent im Statistikreferat des Sekretariats der Kultusministerkonferenz.

E-Mail: marco.mundelius@kmk.org

Anschrift: KMK, Taubenstraße 10, 10117 Berlin