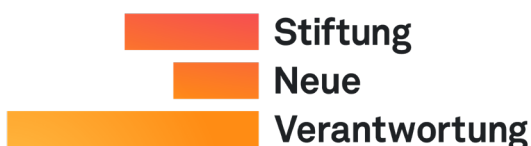


September 2022 · Pegah Maham, Andy Wang

Data Science in Politik und Verwaltung

Empfehlungen für den
erfolgreichen Einsatz
datenbasierter Methoden
im öffentlichen Sektor



Think Tank für die Gesellschaft im technologischen Wandel



Danksagung

Unser Papier stützt sich maßgeblich auf Gespräche, die wir in den vergangenen zwölf Monaten mit Expert:innen geführt haben, die außerhalb Deutschlands Datenlabore in Verwaltungsbehörden aufgebaut oder als Data Scientist in Ministerien gearbeitet haben. Insbesondere möchten wir Jeffrey C. Chen und Alex C. Engler aus den USA, Paul-Antoine Chevalier aus Frankreich, Priit Võhandu aus Estland and Adam Bricknell aus dem Vereinigten Königreich dafür danken, dass sie ihre wertvollen Erfahrungen mit uns geteilt haben.

Dem SNV-Team gebührt für die Unterstützung während des gesamten Recherche- und Veröffentlichungsprozesses ein großer Dank. Innerhalb der Stiftung Neue Verantwortung gilt unser Dank insbesondere Luisa Seeling, Stefan Heumann, Shannon Reitmeir und Andre Weisser.

Das Papier ist Teil des SNV-Themenbereichs „Data Science“, der von der Stiftung Mercator gefördert wird.



Executive Summary

In der öffentlichen Verwaltung spielen datenwissenschaftliche Ansätze bisher nur eine untergeordnete Rolle, anders als in der Privatwirtschaft. Dabei bergen sie großes Potenzial: Datengesteuerte Werkzeuge können dazu beitragen, dass administrative oder politische Entscheidungen auf einer besseren Faktengrundlage getroffen werden. Mit ihrer Hilfe können Prozesse automatisiert und staatliche Ressourcen effizienter eingesetzt werden.

Auch die Bundesregierung hat das Potenzial datengestützter Methoden erkannt. In ihrer Anfang 2021 veröffentlichten Datenstrategie hat sie sich eine deutliche Steigerung der „innovativen und verantwortungsvollen Datenbereitstellung und Datennutzung“ zum Ziel gesetzt. Unter anderem sollen in allen Bundesministerien und im Kanzleramt Datenlabore entstehen. Dieser Prozess ist bereits angelaufen und mit rund 240 Millionen Euro zusätzlicher Haushaltsmittel für die Jahre 2021 bis 2024 finanziert.

Aus dem Aufbau von Data-Abteilungen in Politik und Verwaltung ergeben sich, bei allen Chancen, auch zahlreiche Herausforderungen. Ganz grundsätzlich tragen Data Scientists in diesem Sektor besondere Verantwortung: Ihre Arbeit betrifft oft große Bevölkerungsteile, kann sich über lange Zeiträume hinweg auf wichtige Lebensbereiche auswirken und berührt nicht selten grundlegende Rechte.

Hinzu kommen Hürden bei der praktischen Umsetzung. Nicht immer gelingt es Data-Teams auf Antrieb, innerhalb ihrer Behörde oder Institution passende Kooperationspartner:innen zu finden und zur Zusammenarbeit zu motivieren. Auch starre Verwaltungsprozesse können die Anwendung von Data Science erschweren. Gleichzeitig bringen hohe Inklusions- und Transparenzstandards entsprechende Auflagen und Einschränkungen mit sich.

Dieses Impulspapier ist als Leitfaden zu verstehen. Wir haben uns darin mit der Frage beschäftigt, wie die Integration von Datenlaboren in die Verwaltung gelingen kann, und eine Reihe konkreter Empfehlungen zusammengestellt. Dabei folgen wir der Maxime, dass Data Science in Politik und Verwaltung niemals Selbstzweck, sondern immer Mittel zum Zweck sein sollte. Data-Teams sollten bei der Entwicklung datengetriebener Anwendungen die Nutzer:innen und den konkreten Mehrwert in den Mittelpunkt rücken – in allen Phasen des Prozesses, von der Ideenfindung bis zur Evaluierung.



Vor allem aber ist das berufliche Selbstverständnis entscheidend. Data Scientists in Politik und Verwaltung haben nicht nur eine technische Aufgabe. Mindestens so wichtig für den Erfolg ihrer Arbeit sind ihre Kommunikationsfähigkeit und interdisziplinäres Denken. Data Scientists im öffentlichen Sektor müssen in der Lage sein, politische und administrative Probleme in datenwissenschaftliche Anwendungsfälle zu „übersetzen“ und eine Vielzahl von Nutzer:innen in diesen Prozess einzubinden. Sie müssen ihre Datenprodukte verständlich erklären und einordnen können. Vor allem brauchen sie ein Bewusstsein dafür, wo die Risiken ihrer Methoden liegen: Unerkannte Verzerrungen im Datensatz können große Auswirkungen haben – zum potenziellen Schaden ganzer Bevölkerungssegmente.

Unser Papier folgt der Entwicklung von Datenprodukten entlang der vier Phasen „Ideenfindung“, „Prioritätensetzung“, „Umsetzung“ und „Evaluation“. Jedes Kapitel enthält eine Liste mit den wichtigsten Dos und Don'ts beim Aufbau von Datenlaboren. Ein weiteres Kapitel beschäftigt sich mit dem Recruiting und der Zusammensetzung von Data-Teams. Im öffentlichen Sektor kann es schwierig sein, die richtigen Mitarbeiter:innen zu finden, weil Datenlabore vielfältige Kompetenzen bündeln und mit der Privatwirtschaft um Talente konkurrieren müssen. Wir empfehlen, die Stellen durch ressortübergreifende Austauschmöglichkeiten attraktiver zu gestalten. Konzentriert werden sollte die Suche auf Kandidat:innen, die eine ausgeprägte Gemeinwohlorientierung und Interesse für den politischen Kontext des Arbeitsfelds mitbringen.



Inhaltsverzeichnis

Executive Summary	3
Einleitung	6
1. Ideenfindung	13
2. Prioritätensetzung	16
3. Umsetzung	20
4. Evaluation	23
5. Teams	27
Fazit	30



Einleitung

In der Privatwirtschaft ist Data Science seit Jahren etabliert. In der öffentlichen Verwaltung hingegen spielen datenwissenschaftliche Ansätze bisher nur eine untergeordnete Rolle. Dabei bergen sie großes Potenzial¹: **Regierungs- und Verwaltungsbehörden können datengesteuerte Werkzeuge einsetzen, um interne Prozesse und Bürgerservices zu optimieren.** Zu diesen Werkzeugen zählen etwa Instrumente zur Sprachverarbeitung, mit denen relevante Informationen aus Textdaten extrahiert und nutzbar gemacht werden können. Auch visuell aufbereitete Daten, wie beispielsweise COVID19-Infektions-Dashboards, sind ein klassischer Anwendungsfall. Mithilfe von Data Science lassen sich Ressourcen freisetzen, die für die Bewältigung anderer Aufgaben effizienter eingesetzt werden können. Datengesteuerte Methoden stärken zudem das Vertrauen der Bürger:innen in die Fähigkeit der öffentlichen Verwaltung, moderne digitale Dienste anzubieten. **Behörden können die möglichen Vorteile datengestützter Methoden (etwa mehr Transparenz, Objektivität und Schnelligkeit) auch nutzen, um ihre Entscheidungsprozesse zu verbessern – sowohl in ihren täglichen Abläufen als auch bei längerfristigen Weichenstellungen.** Nicht zuletzt führt der Einsatz von In-House-Data Scientists zu mehr technologischer Souveränität: Ministerien und Verwaltungsbehörden werden unabhängiger von Auftragnehmer:innen und Beratungsfirmen, und die Wahrscheinlichkeit steigt, dass wichtige Datenkompetenzen im Lauf der Zeit auch in anderen Teilen dieser Behörden Verbreitung finden (sogenannte „Spillover-Effekte“).

Schon die vorherige Bundesregierung hat das Potenzial datengestützter Methoden erkannt und im Januar 2021 die erste deutsche Datenstrategie veröffentlicht. Darin stellt sie fest, dass „Daten in Deutschland und in Europa heute noch immer zu wenig genutzt werden“.² Dementsprechend setzt sie sich das Ziel einer deutlichen Steigerung der „innovativen und verantwortungsvollen Datenbereitstellung und Datennutzung“.³ Einige Monate später stellte die Bundesregierung im Rahmen des Deutschen Aufbau- und Resilienzplans (DARP) 239 Millionen Euro für den Aufbau von Datenkapazitäten – einschließlich der Schaffung von Datenlaboren in allen Bundesministerien und im Kanzleramt – bereit, um die Umsetzung der Strategie voranzutreiben.⁴

¹ Siehe auch: Engler, A. (2022). *Institutionalizing Data Analysis in German Federal Governance*.

² S. 5, Bundesregierung (2021). *Datenstrategie der Bundesregierung*.

³ S. 6, Bundesregierung (2021). *Datenstrategie der Bundesregierung*.

⁴ S. 434, Bundesfinanzministerium (2020). *Komponente 2.1 Daten als Rohstoff der Zukunft* In Deutscher Aufbau- und Resilienzplan (DARP).

Der Aufbau dieser Datenlabore (im Folgenden auch Data-Science-Abteilungen oder -Teams genannt) ist komplex, weil eine Reihe von Besonderheiten berücksichtigt werden muss. Im öffentlichen Sektor gibt es andere Zwänge und Anforderungen als in der Privatwirtschaft. Staatliche Entscheidungen betreffen nicht selten alle Bürger:innen, auch die schwächsten, und entfalten ihre Wirkung oft über lange Zeiträume hinweg. Zudem können Bürger:innen sich ihnen in der Regel nicht entziehen oder einen alternativen Dienstleister wählen. **Staatliche Data-Science-Teams tragen deshalb eine besondere Verantwortung und müssen im Hinblick auf Transparenz und Legitimität ihrer Arbeit hohe Standards und Erwartungen erfüllen.**

Neben diesem grundsätzlichen Unterschied zur Privatwirtschaft gibt es noch weitere, teils damit verknüpfte Herausforderungen für den Einsatz von Data Science im öffentlichen Sektor:

- Die Ziele und Abwägungen einer staatlichen Institution sind oft komplexer als die eines Unternehmens. Es gilt, vielfältige gesellschaftliche Interessen und weitreichende Interdependenzen zu berücksichtigen. Daher erfordert die erfolgreiche Einbindung von Data Science in diesem Sektor noch mehr Interdisziplinarität.
- In der Privatwirtschaft entsteht durch Marktfeedback und Wettbewerbsdruck die Notwendigkeit, innovative Werkzeuge einzusetzen, Prozesse zu automatisieren und Daten bei der Entscheidungsfindung zu berücksichtigen. Das schafft starke Anreize, mit Data-Science-Abteilungen zusammenzuarbeiten. In staatlichen Einrichtungen hingegen sind diese Anreize deutlich schwächer ausgeprägt oder fehlen gänzlich.
- Starre Verwaltungsprozesse und institutionelle Beschränkungen lassen weniger Flexibilität zu. So erschweren zum Beispiel Gehaltsobergrenzen und Softwarebeschränkungen den Wettbewerb um Talente mit der Privatwirtschaft.
- Aufgrund technologischer Lücken und kultureller Prägungen⁵ sind staatliche Institutionen oft nicht mit den Methoden der Data Science vertraut und haben weniger Erfahrung mit modernen Arbeitsabläufen, etwa mit feedbackintensiven Prozessen. Dies kann die Arbeit von Data-Science-Teams erschweren.

⁵ Heumann, S. (2021). *Scheinlösung Digitalministerium*.

- Das Gleichheitsgebot und demokratische Rechenschaftspflichten spielen eine wichtige Rolle; deshalb sind die Standards der öffentlichen Hand für Inklusion und Transparenz in der Regel höher als in der Privatwirtschaft. So sind etwa barrierefreie Visualisierungen für Menschen mit Sehbehinderungen vorgeschrieben. Ein weiteres Beispiel sind Machine-Learning-Modelle, bei denen nicht nachvollziehbar ist, wie sie zu ihren Ergebnissen kommen („Black-Box-Modelle“). Solche Modelle können bei diskriminierungsanfälligen Anwendungen nicht eingesetzt werden. Der Umfang potenziell nutzbarer Datenprodukte und -methoden ist deshalb eingeschränkt.
- Die Integration datenwissenschaftlicher Produkte und Methoden in die Verwaltung findet nicht nur unter der kritischen Beobachtung der Öffentlichkeit, sondern auch der Oppositionsparteien statt. Das treibt die politischen Kosten von Fehlern in die Höhe und senkt den Anreiz, Risiken einzugehen, Irrtümer offenzulegen und aus ihnen zu lernen.

Angesichts dieser strukturellen Besonderheiten ist es für Ministerien und Verwaltungsbehörden entscheidend, bei der Integration von Datenlaboren in bestehende Strukturen strategisch vorzugehen. **Neu aufgebaute oder im Aufbau befindliche Data-Science-Abteilungen sollten einem nutzerzentrierten Ansatz folgen, um sich erfolgreich zu etablieren und nachhaltige Ergebnisse liefern zu können.** In diesem Impulspapier haben wir eine Reihe von Empfehlungen und potenziellen Fallstricken zusammengestellt, um die Chancen für eine gelungene Einbindung von Data Science in die öffentliche Verwaltung zu erhöhen. Dabei unterteilen wir den Produktentwicklungsprozess in einem Datenlabor in verschiedene Phasen und erörtern für jede einzelne Phase anhand einer Checkliste, was getan und vermieden werden sollte (Dos und Don'ts).

Angesichts der beschriebenen Anforderungen für Datenwissenschaftler:innen im öffentlichen Sektor beschäftigen wir uns in einem fünften Kapitel außerdem mit der Frage, wie ein starkes Data-Science-Team aufgebaut werden kann und welche Kompetenzen es bündeln sollte.

Unser Papier stützt sich einerseits auf Gespräche, die wir im vergangenen Jahr mit Praktiker:innen⁶ geführt haben, die außerhalb Deutschlands Datenlabore in Verwaltungsbehörden aufgebaut oder als Data Scientist in Ministerien gearbeitet haben – und andererseits auf unsere eigenen Erfahrungen bei

⁶ Unter anderem mit Jeffrey C. Chen und Alex C. Engler aus den USA, Paul-Antoine Chevalier aus Frankreich, Priit Võhandu aus Estland und Adam Bricknell aus dem Vereinigten Königreich.



der Stiftung Neue Verantwortung. In den vergangenen zwei Jahren haben wir dort ein Data-Science-Team neu aufgebaut, das seither die unabhängigen Analysen des Think Tanks mit datengesteuerten Produkten unterstützt. So haben wir beispielsweise eine interaktive Visualisierung des deutschen Cybersicherheitsökosystems erstellt,⁷ eine Trendanalyse zu Halbleiterkonferenzbeiträgen durchgeführt⁸ und eine Methode zur Identifizierung relevanter Stakeholder mittels Social-Media-Netzwerken entwickelt („Fischnetz-Methode“).⁹

Auch wenn sich dieses Impulspapier in erster Linie mit der Etablierung datenwissenschaftlicher Prozesse in Behörden beschäftigt, sind unsere Vorschläge auch auf Nichtregierungsorganisationen (NGOs) und Think Tanks übertragbar, die vor ähnlichen Herausforderungen stehen.

Data Science und nutzerzentrierte Datenprodukte

Data Science umfasst Disziplinen von der Statistik bis zur Softwareentwicklung und kann im Allgemeinen dazu angewandt werden, Prozesse zu automatisieren und mit Hilfe verschiedener Methoden neue Erkenntnisse zu gewinnen. Diese Methoden ermöglichen es unter anderem, neue Datenquellen zu erschließen (Web Scraping oder APIs) und auf dem neuesten Stand zu halten (Datenpipelines), Textdaten zu analysieren (Natural Language Processing), Prognosen zu stützen (Zeitreihenanalysen), komplexe Informationen zu vereinfachen (Clusteranalysen), Hypothesen zu testen (statistische Inferenz), Informationen besser zugänglich zu machen (interaktive Visualisierungen) oder Entscheidungen zu unterstützen (Klassifizierungs- und Vorhersagemodelle).

7 Herpig, S., Rupp, C., Maham, P. und Semenova, A. (2022). *Germany's Cybersecurity Architecture*.

8 Kleinhans, J., Hess, J., Maham, P. und Semenova, A. (2021). *Who Is Developing the Chips of the Future?*.

9 Maham, P. und Semenova, A. (2022). *Fishnet Method and Code*.

Andere Länder haben bereits damit begonnen, datenwissenschaftliche Methoden in ihren Verwaltungen anzuwenden,¹⁰ und auf diese Weise das Potenzial datengesteuerter Prozesse demonstriert. Die folgenden zwei Beispiele aus den USA und Großbritannien zeigen, wie sich datenwissenschaftliche Methoden erfolgreich in staatlichen Einrichtungen anwenden lassen:

- Mustererkennung zur Aufdeckung von Insiderhandel (USA)
Data Science kann sehr effektiv dazu beitragen, eine Brücke zwischen geschriebenem Gesetz und Rechtspraxis zu schlagen. Dieses Ziel verfolgen auch Produkte, die von der US-amerikanischen Wertpapier- und Börsenaufsichtsbehörde (SEC) eingesetzt werden, um Insiderhandel aufzudecken.¹¹ Damit diese Instrumente für die Behörden hilfreich sind, müssen sie nachvollziehbar sein und sich unkompliziert in bestehende Prozesse einfügen. Aus diesem Grund ist das Advanced Relational Trading Enforcement Metrics Investigation System (ARTEMIS) nicht vollständig automatisiert. Vielmehr ermitteln die SEC-Mitarbeitenden zunächst „Trigger-Ereignisse“, die den Börsenwert eines Unternehmens stark beeinflussen können. Sobald potenzielle Insiderhändler:innen identifiziert sind, analysiert das ARTEMIS-Tool mit Hilfe von Mustererkennung deren frühere Geschäfte, um Anomalien im Handelsverhalten zu ermitteln. Da ARTEMIS den Erwartungen und Bedürfnissen der Endnutzer:innen entgegenkommt, ist es zu einem wertvollen und zeitsparenden Instrument geworden.
- Datengestützte Segmentierung für die Spezialisierung von Sozialarbeiter:innen (UK)
Im englischen Newcastle werden im Rahmen des Programms „Family Insights“ Daten verwendet, um Sozialarbeiter:innen zu entlasten. Hierzu werden betreuungsbedürftige Familien nach einer Reihe von Merkmalen gruppiert und dann Fallbearbeiter:innen zugewiesen, die auf derartige Fälle spezialisiert sind.¹²

10 Siehe etwa die folgenden Beispiele:

- Großbritannien: Behavioural Insights Team. (2017). *Using data science in policy: a report by the Behavioural Insights Team. Report.*

- USA: Engstrom, D. F., Ho, D. E., Sharkey, C. M., und Cuéllar, M. F. (2020). *Government by Algorithm: Artificial Intelligence in Federal Administrative Agencies.* Administrative Conference of the United States.

- EU: Misuraca, G. und Van Noordt, C. (2020). *AI Watch - Artificial Intelligence in Public Services* Publications Office of the European Union, Luxembourg.

11 S. 24, Engstrom, D. F., Ho, D. E., Sharkey, C. M., und Cuéllar, M. F. (2020). *Government by Algorithm: Artificial Intelligence in Federal Administrative Agencies.* Administrative Conference of the United States.

12 S. 13, Symons, T. (2016). *Wise Council – Insights from the Cutting Edge of Data-driven Local Government.* Nesta und Local Government Association.



Auf diese Weise wird vermieden, dass die Sozialarbeiter:innen zu viele unterschiedliche Fälle annehmen.¹³ Stattdessen können sie dank der gezielten Fallzuteilung ihre Betreuungsarbeit effizienter und präziser verrichten. Anfangs gab es noch Zweifel an der Wirksamkeit der Segmentierung, vor allem mit Blick auf komplexe Fälle; inzwischen aber ist die Akzeptanz für das Vorgehen hoch. Im Rahmen des Family-In-sight-Programms finden nun regelmäßig Fallübergabe-Gespräche statt, um die Zuweisungskriterien zu verfeinern und um sicherzustellen, dass die Segmentierung für alle Sozialarbeiter:innen reibungslos funktioniert und keinen zusätzlichen Aufwand erzeugt.

In diesem Impulspapier verwenden wir den Begriff „Datenprodukte“ im weitesten Sinne. Er kann sich sowohl auf Visualisierungen wie die eingangs erwähnten COVID19-Infektions-Dashboards beziehen als auch auf die Schaffung einer zentralen Datenbank für Verkehrsdaten; er umfasst Werkzeuge, die papierbasierte Arbeitsabläufe in automatisierte Prozesse umwandeln, ebenso wie die Auswertung von Energieverbrauchsdaten, die als energiepolitische Entscheidungshilfe dienen.

Unabhängig von der Art des Datenprodukts sollte jedes Produkt klare Endnutzer:innen haben – also eine oder mehrere Personen oder auch Abteilungen, die einen Nutzen davon haben. Dabei kann es sich um Verwaltungsangestellte handeln, die täglich mit einem Datensatz arbeiten müssen, um interessierte Bürger:innen, die auf offene Datenquellen zugreifen, oder auch um Analyst:innen, die Dashboards für ihre Entscheidungen nutzen. Damit Datenprodukte den Endnutzer:innen wirklich helfen, müssen sie direkt auf deren Bedürfnisse zugeschnitten werden. Dementsprechend sollte ihre Entwicklung stets von den Bedürfnissen der Nutzer:innen geleitet werden. Diesen Prozess bezeichnet man als „nutzerzentriertes Design“.¹⁴


¹³ S. 24, Beninger, Kelsey et al. (2017). *Newcastle City Council's Family Insights Programme*. Department for Education (UK).

¹⁴ Chen, J. C., Rubin, E. A., und Cornwall, G. J. (2021). *Data Science for Public Policy*. Springer International Publishing.



Der nutzerzentrierte Prozess besteht aus vier Phasen (siehe Abbildung unten), von denen sich jeder einzelne auf die Nutzer:innen und ihre Bedürfnisse bezieht:

1. Ideenfindung: Das Team identifiziert die Endnutzer:innen und ihre Bedürfnisse.
2. Prioritätensetzung: Gemeinsam mit den Nutzer:innen bewertet das Team die Kosten und die potenzielle Wirkung eines Projekts, um zu entscheiden, ob es begonnen beziehungsweise fortgesetzt werden soll.
3. Umsetzung: Das Team entwickelt Minimalversionen des Produkts und holt bei jeder Weiterentwicklung das Feedback der Nutzer:innen ein.
4. Evaluation: Das Team testet das Produkt und bewertet dessen Vorteile, Risiken und Grenzen gemeinsam mit den Nutzer:innen.



Die vier Schritte des nutzerzentrierten Prozesses: Ideenfindung, Prioritätensetzung, Umsetzung und Evaluation. Die Evaluation wirkt sich auf die beiden vorangegangenen Schritte aus (nach Chen 2021).

In diesem Impulspapier wird jede der oben genannten Phasen einzeln untersucht, da jede von ihnen eigene Herausforderungen birgt.

1. Ideenfindung

Wie können Data-Science-Teams geeignete Projektideen entwickeln – insbesondere dann, wenn sich das Datenlabor noch im Aufbau befindet?

Mögliche Anwendungsfälle für Data Science zu identifizieren, ist weder im öffentlichen Sektor noch in der Privatwirtschaft einfach. Das liegt daran, dass Data-Science-Abteilungen üblicherweise nicht von einem Problem ausgehen, das gelöst werden muss, wie es in den meisten anderen Ressorts oder Abteilungen der Fall ist. Vielmehr läuft es umgekehrt: Data-Science-Teams verfügen über eine spezielle Methode; mit dieser versuchen sie, ein konkretes Problem zu finden, um es dann zu lösen.

Langfristig sollten die meisten Projekte von den Expert:innen und Mitarbeitenden der jeweiligen Behörden identifiziert und dann an die Data-Science-Abteilung herangetragen werden. In der Anfangsphase, wenn sich das Datenlabor noch im Aufbau befindet, wird dies voraussichtlich jedoch nicht so oft passieren. Zu diesem Zeitpunkt wird sich die Gewohnheit, datengesteuerte Ansätze in Betracht zu ziehen, noch nicht behördenweit durchgesetzt haben. Aufgrund fehlender Erfahrung und Ausbildung dürfte das Bewusstsein für datenwissenschaftliche Anwendungen noch nicht sehr ausgeprägt sein. **Daher wird zu Beginn das Data-Science-Team in hohem Maße für die Identifizierung von Anwendungsfällen zuständig sein.** Damit diese „Ideenpipeline“ funktioniert, ist die Integration des Data-Science-Teams in die bestehenden Strukturen von entscheidender Bedeutung. **Der notwendige Austausch kann nur zustande kommen, wenn die Data-Teams nicht in Silos arbeiten.**

In der Anfangsphase stehen die Daten-Abteilungen vor weiteren Herausforderungen. Sie müssen erst einmal den Wert ihrer Arbeit unter Beweis stellen, um potenzielle Partner:innen für die Zusammenarbeit zu gewinnen. Gleichzeitig brauchen sie eben jene Partner:innen, um überhaupt erst passende Anwendungsfälle identifizieren und den Nutzen ihrer Arbeit demonstrieren zu können – ein klassisches Henne-und-Ei-Problem. Unsere Empfehlung an dieser Stelle lautet, sich anfangs auf sogenannte Early Adopters zu konzentrieren; also auf Mitarbeitende innerhalb der Behörde oder des Ministeriums, die begeisterungsfähig und bereit sind, datengetriebene Methoden auszuprobieren und innovative Projekte voranzutreiben.

Das folgende – fiktive – Beispiel verdeutlicht, wie wichtig es ist, die Nutzer:innen und ihre Bedürfnisse zu verstehen, um die Brücke zwischen Data Science und den herkömmlichen Arbeitsprozessen in der öffentlichen Verwaltung zu schlagen: Die Angestellten einer Behörde müssen Hunderte von Postleitzahlen manuell in eine Suchmaschine eingeben, um geografische Koordinaten ausfindig zu machen und Entfernungsberechnungen vorzunehmen. Da die Abteilung keine Erfahrung mit Data Science hat, ist den Mitarbeitenden nicht bewusst, dass dieser Arbeitsprozess mit Hilfe datengestützter Tools optimiert werden könnte. Die Data-Science-Abteilung hingegen hat Erfahrung mit der Verwendung von APIs zur Automatisierung solcher Aufgaben. In diesem Fall könnten die Postleitzahlen mittels einer API automatisch in Koordinaten umgewandelt werden. Damit aber das Data-Science-Team eine Verbindung herstellt zwischen der zu lösenden Aufgabe und den zur Verfügung stehenden Tools, muss es die Aufgaben und Abläufe innerhalb der Behörde gut kennen. Je mehr Data-Expert:innen über die Nutzer:innen, deren Aufgaben und Arbeitsumfeld erfahren, desto besser können sie geeignete Anwendungsgebiete für ihre Tools und Methoden identifizieren.

Ziel der Ideenfindungsphase ist es, potenzielle Anwendungsfälle zu finden, bei denen Datenwerkzeuge zum Einsatz kommen können – etwa zur Prozessoptimierung, Informationsgewinnung oder Entscheidungsfindung. **Data-Teams sollten sich dabei stets bewusst machen, dass Data Science ein Mittel zum Zweck ist, und sich am möglichen Impact ihrer Arbeit orientieren.** Dann wird es ihnen leichter fallen, den Mehrwert datenwissenschaftlicher Methoden zu belegen und mehr Menschen für Data-Science-Prozesse zu begeistern.

Was Data-Science-Teams in der Ideenfindungsphase beachten sollten, haben wir in der folgenden Empfehlungsliste zusammengefasst:

- Do** | **Machen Sie es zu Ihrer Priorität, die Endnutzer:innen und ihren Kontext zu verstehen.**
Arbeiten Sie sich in bestehende Arbeitsabläufe ein, anstatt zu versuchen, neue Prozesse zu etablieren. Führen Sie (formelle oder informelle) Gespräche und Nutzerbefragungen durch oder verschaffen Sie sich einen Eindruck als stille:r Beobachter:in. So erfahren Sie nicht nur, was die Nutzer:innen brauchen, sondern auch, in welchem größeren Kontext ihre Arbeit stattfindet. Vor allem wenn ein Datenlabor gerade erst seine Arbeit aufnimmt, ist es für die Nutzer:innen oft schwer einzuschätzen, wie ihnen datengestützte Prozesse weiterhelfen können.

Rechnen Sie damit, dass Sie Ihre Projektideen verfeinern müssen.

Wenn sich Ihr Team noch im Aufbau befindet, wissen andere Personen in der Organisation womöglich noch nicht, wie sie mit der Data-Science-Abteilung interagieren sollen und wie die Entwicklung von Datenprodukten funktioniert. Ein guter Ausgangspunkt für die Zusammenarbeit sind gemeinsame Whiteboarding- oder Brainstorming-Sitzungen, in denen Ideen oder Vorschläge gesammelt werden. Entwickeln Sie ein gemeinsames Verständnis des Problems und möglicher datengetriebener Lösungen.

Halten Sie die Kommunikationskanäle offen.

Gerade weil potenzielle Nutzer:innen möglicherweise nicht wissen, wie Data Science ihnen helfen kann, sollten Sie früh die Voraussetzungen für eine offene Zusammenarbeit schaffen. Gehen Sie proaktiv auf Mitarbeitende anderer Abteilungen zu und pflegen Sie eine Politik der offenen Tür. So erleichtern Sie anderen nicht nur den Zugang zu Ihrem Team, sondern fördern auch eine Kultur, in der sich Menschen gerne an Ihre Abteilung wenden, wenn sie Ideen oder Fragen haben.

Don't**Data Science sollte kein Selbstzweck sein.**

Es mag verlockend sein, das Potenzial von Data Science mit möglichst innovativen Methoden oder Tools zu demonstrieren. Letztlich aber laufen solche Demonstrationen ins Leere, wenn sie nicht einem konkreten Zweck innerhalb Ihrer Organisation dienen. Wie gesagt: Data-Science-Ansätze sollten immer Mittel zum Zweck sein. Stellen Sie sicher, dass sich jedes Projekt eng an den Bedürfnissen der Nutzer:innen orientiert.¹⁵

Stellen Sie Ihr Team darauf ein, dass es wahrscheinlich nicht gleich mit technisch anspruchsvollen Projekten loslegen wird.

Wenn Ihr Team noch ganz am Anfang steht, wird die erste Welle von Arbeitsaufträgen vermutlich schlichterer Natur sein – beispielsweise deskriptive Statistiken oder das Erstellen einfacher Datensätze. Machen Sie Ihrem Team klar, dass es später mehr Raum dafür geben wird, komplexere Methoden zu nutzen. Werden die zu Anfang eher simplen Projekte erfolgreich durchgeführt, schafft das Akzeptanz für technisch anspruchsvollere Projekte in der Zukunft.

¹⁵ Office for Artificial Intelligence (UK) (2020). [Guidelines for AI Procurement](#).

Es kann unterschiedliche Auffassungen darüber geben, welche Rolle die Data-Science-Abteilung innerhalb einer Organisation spielt.

Zu Beginn ist womöglich unklar, welche Aufgaben in die Verantwortung der Datenabteilungen fallen: Wo hört die Arbeit der IT-Abteilung oder des Softwareentwicklungs-Teams auf, wo fängt die Arbeit der Data-Science-Einheit an? Bleiben Sie offen für alle Ideen, selbst wenn diese außerhalb des vorgesehenen Arbeitsbereichs Ihres Teams liegen. Vielleicht fallen Ihnen dabei Routinen oder Prozesse auf, die automatisiert werden können, oder Sie gewinnen andere Erkenntnisse, die für Ihr Team von Nutzen sind.

2. Prioritätensetzung

Welche Data-Science-Projektideen sollten Vorrang haben?

Gerade in Behörden kann es vorkommen, dass Technologieprojekte mit hohem Kosten- und Ressourcenaufwand entwickelt werden, nur um später wieder verworfen zu werden, weil sich keine passenden Anwendungsfälle finden. **Wichtig ist deshalb, dass Projekte priorisiert werden, indem ihre potenzielle Wirkung und ihr Investitionsumfang gegeneinander abgewogen werden.**¹⁶

Data-Science-Abteilungen sollten zunächst erörtern, was das ideale Ergebnis des Projekts wäre. **Relevant ist dabei die Frage, wie sich das Projekt konkret auf die Nutzer:innen auswirkt:** Wie viele Stunden können durch die Umsetzung künftig eingespart werden? Wie lassen sich die Erkenntnisse der Datenanalyse genau nutzen? Daten-Teams sollten Abstand nehmen von Projekten, die in die „So-what“-Kategorie fallen – Projekte also, die keine greifbare und sinnvolle Veränderung bewirken.

Im nächsten Schritt sollten Datenexpert:innen die Entwicklungsparameter des Projekts verfeinern und so früh wie möglich konkret werden: Welche Daten sollen verwendet werden? Sind diese bereits vorhanden oder muss ein Datensatz erstellt werden? Welche Infrastruktur ist nötig und wie leicht ist diese zugänglich? Welche Methoden wird das Datenlabor anwenden und ist das Team dafür gerüstet? Anhand dieser Fragen sollte die Data-Abteilung

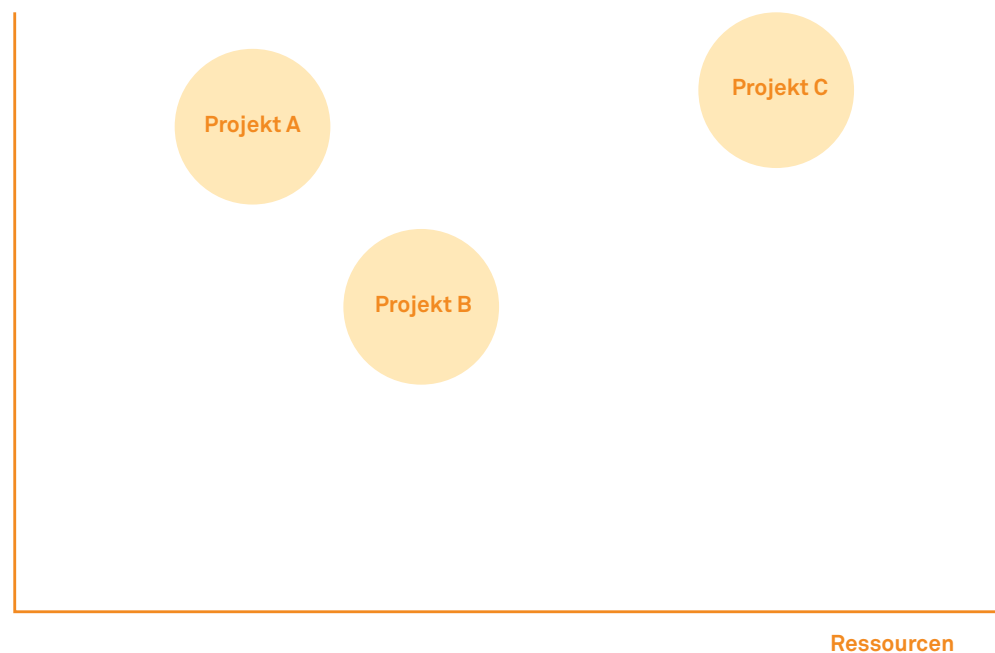
¹⁶ S. 79 bietet einen Rahmen für eine noch spezifischere Konzeptualisierung der Wirkung, Misuraca, G., und Van Noordt, C. (2020). *AI Watch—Artificial Intelligence in Public Services*. Publications Office of the European Union, Luxembourg.



nicht nur eine bessere Vorstellung vom konkreten Ergebnis des Produkts bekommen, sondern auch ein besseres Gefühl für die Ressourcen entwickeln, die sie für die Entwicklung des Produkts aufwenden muss – insbesondere Zeit, Geld und Arbeitskraft. Ebenso berücksichtigt werden sollten in dieser Phase Faktoren wie die Wahrscheinlichkeit von Engpässen, die Erfolgsaussichten des Projekts und potenzielle rechtliche oder administrative Hindernisse.

Auf Grundlage der erwarteten Wirkung und der benötigten Ressourcen sollte beurteilt werden, ob das Projekt zum jetzigen Zeitpunkt die Investition wert ist. Solange sich das Team noch im Aufbau befindet, sollte der Schwerpunkt dabei auf Produkten liegen, die mit niedrigem Aufwand vergleichsweise große unmittelbare Wirkung entfalten können. Ehrgeizige Projekte mögen verlockend sein, sie erfordern aber deutlich mehr Vertrauen seitens der auftraggebenden Behörde. Dieses kann man aber insbesondere durch verlässlich und erfolgreich abgeschlossene Projekte gewinnen, auch wenn diese nur einen begrenzten Umfang haben.

Abbildung 2 Wirkung



Beispiel eines Entscheidungsrasters für die Prioritätensetzung. Die horizontale Achse gibt den Umfang der erforderlichen Ressourcen an, während die vertikale Achse die Wirkung des Projekts beschreibt. In diesem Schaubild sollte Projekt A gegenüber Projekt B und C bevorzugt werden, weil A eine größere Wirkung als B entfaltet und gleichzeitig weniger Ressourcen als B und C erfordert.

Do Klären Sie vorab, wie Sie die Nutzer:innen in den Entwicklungsprozess einbeziehen können.

In der Abwägung, ob und mit welchem Aufwand ein Projekt durchgeführt werden kann, sollten Sie auch die Frage berücksichtigen, inwieweit sich die Nutzer:innen beteiligen können. Denn deren Ressourcen – insbesondere Zeit – sind für den Erfolg des Projekts oft genauso wichtig wie Ihre eigenen. Stellen Sie frühzeitig klar, wie Nutzer:innen mit Blick auf Feedback, Tests, Fachwissen und Kommunikation eingebunden werden können, und vergewissern Sie sich, dass auch andere Abteilungen, mit denen Sie bei diesem Projekt zusammenarbeiten, in gleichem Maße beteiligt sind. Sonst kann es zu unerwarteten Engpässen kommen.

Bewerten Sie die Risiken vor Beginn des Entwicklungsprozesses.

Bevor Sie Zeit in die Entwicklung eines Projekts investieren, sollten Sie die technischen, politischen, ethischen und rechtlichen Hürden bedenken, die Sie daran hindern könnten, das ideale Endprodukt zu entwickeln und Akzeptanz dafür zu schaffen. Beziehen Sie deshalb so früh wie möglich alle relevanten Interessengruppen ein, einschließlich der Rechtsabteilung. Beurteilen Sie dann, ob und wie Sie mit potenziellen Hindernissen umgehen können.

Legen Sie einen Ideenspeicher für Projekte an, die Sie zunächst zurückstellen müssen.

Legen Sie für Ihr Team ein Verzeichnis all jener Projektideen an, die momentan nicht durchführbar sind oder bislang nicht priorisiert wurden. Stellen Sie sicher, dass alle relevanten Informationen dokumentiert werden; so müssen Sie nicht wieder bei null anfangen, wenn die Durchführung eines Projekts zu einem späteren Zeitpunkt erneut abgewogen wird. Ein solches Verzeichnis kann auch eine Argumentationshilfe sein, wenn Sie mit den Beteiligten erörtern, warum ein Projekt zu einem bestimmten Zeitpunkt (noch) nicht durchführbar ist.

Don't Warten Sie nicht auf ideale Bedingungen für ein Projekt.

Nimmt eine Data-Science-Einheit erstmals die Arbeit auf, dann ist es sehr wahrscheinlich, dass die Datenlage noch unübersichtlich ist oder an vielen Stellen technisches Werkzeug fehlt. Zudem sind Daten so gut wie nie vollständig repräsentativ oder unverzerrt. Bevor Sie eine Idee verwerfen, sollten Sie sich deshalb fragen, wie die nächstbeste Alternative aussehen würde oder was der vorzeitige Abbruch eines Projekts bedeuten würde. Die Verlässlichkeit von COVID19-Fallzahlen hängt



beispielsweise maßgeblich von der Anzahl der durchgeführten Tests ab. Trotzdem ist es besser, diese – unvollständigen – Zahlen zu erfassen, als gar keine Daten zu haben.

Explorative Datenanalysen sollten nur durchgeführt werden, um zu nutzerrelevanten Fragen zu gelangen.

Wenn Sie einen interessanten Datensatz vorfinden, dann sollten Sie den Umfang Ihrer explorative Datenanalyse nach und nach eingrenzen. Orientieren Sie sich daran, wo der potenzielle Nutzen eines Produkts oder einer Erkenntnis für die Endnutzer:innen liegen kann. Bedenken Sie, dass Sie von der wissenschaftlichen Methode abweichen, wenn Sie Ihre Hypothese auf Grundlage derselben Daten aufstellen und testen. Damit riskieren Sie, dass zufällige Korrelationen statistisch signifikant erscheinen.¹⁷

Nicht alle Daten oder Werkzeuge, die bereits aufbereitet sind oder zur Verfügung stehen, sind automatisch auch nützlich.

Vermeiden Sie den Fehlschluss der irreversiblen Kosten (Sunk Cost Fallacy): Es lohnt sich nicht, ein Projekt fortzuführen, nur weil Sie bereits eine Menge Arbeit hineingesteckt haben. Treffen Sie Entscheidungen stets unter Berücksichtigung des jeweiligen Anwendungsfalls und der potenziellen Wirkung eines Projekts. Lassen Sie sich nicht von einem besonders aufregenden Datensatz oder von innovativen Methoden von dem wichtigsten Bewertungsmaßstab ablenken: der Frage, was das Projekt den Endnutzer:innen bringt. Managen Sie auch die Erwartungen im Team und stellen Sie klar, dass viele Bemühungen nicht in fertige Produkte münden, sondern abgebrochen werden müssen.

¹⁷ Das Aufstellen von Hypothesen und das Testen dieser Hypothesen an demselben Datensatz kann zu falschen Ergebnissen führen. Wenn eine Vielzahl von Hypothesen getestet wird (durch eine breite Untersuchung der Daten), wird wahrscheinlich auch eine zufällige Korrelation gefunden. Siehe dazu auch die Diskussionen um „p-hacking“ oder „HARKing“.

3. Umsetzung

Wie schafft man effiziente Produkte, die auch genutzt werden?

Die meisten Datenprodukte¹⁸ werden am besten auf agile Art und Weise entwickelt.¹⁹ **In einem agilen Entwicklungszyklus wechseln die beteiligten Teams mehrfach zwischen der Erstellung sogenannter Minimalversionen (Minimum Viable Products, MVPs) und Feedbackschleifen hin und her.** Auf diese Weise bauen Datenteams Vertrauen in ihre Arbeit auf und vermeiden eine Fehlallokation von Ressourcen. Wird beispielsweise ein Dashboard erstellt, dann sollte die Kennzahl zunächst so einfach wie möglich dargestellt werden. Sobald die Pipeline zur Einspeisung der Daten in das Dashboard vollständig aufgesetzt ist, kann die Visualisierung verfeinert oder können weitere Indikatoren hinzugefügt werden.

In den einzelnen Phasen des agilen Entwicklungsprozesses, die auch als „Sprint“ bezeichnet werden, setzen sich die Teams ein Zeitlimit, um eine bestimmte Anzahl von Aufgaben zu erfüllen. Diese klaren Zeitvorgaben sollen verhindern, dass die Teams zu früh nach Perfektion streben.²⁰ Wenn eine Projektidee als realisierbar eingeschätzt wird, sollten sich die Teams im ersten Sprint auf die **Erstellung eines Prototyps** konzentrieren. Diese schlanke „Version 1“ sollte demonstrieren, dass die wichtigsten Ziele des Projekts im Sinne der Endnutzer:innen erreicht werden können. Denn je schneller die Teams ein vielleicht noch nicht perfektes, aber tragfähiges Produkt vorweisen können, desto schneller erhalten sie Unterstützung für ihre Arbeit. Gleichzeitig kann so vermieden werden, dass das Projekt mit unnötigem Ballast überfrachtet wird.

Nach Abschluss eines jeden Sprints sollte das Datenteam den Beteiligten den jeweiligen Stand seiner Arbeit präsentieren. (Kapitel 4 behandelt das Thema kurz- und langfristige Evaluation ausführlich.) Zu Beginn sollten die Teams nicht nur zeigen, dass sie die Projektanforderungen erfüllen können, sondern auch, dass sie offen für das Feedback anderer Abteilungen sind. Denn gerade, wenn ein Projekt schon weit vorangeschritten ist, ohne dass frühzeitig Feedback eingeholt wurde, kann der Sunk-Cost-Effekt zu Widerstand gegen spätere Änderungen am Produkt führen – sogar dann, wenn diese für die Benutzer:innen von Vorteil sind.

18 Wissenschaftliche Studien sollten nicht agil durchgeführt werden. Wie in Fußnote 17 beschrieben, stehen agile Iterationen und wissenschaftliche Best Practices in Spannung zueinander. Die Hypothesenprüfung und die Hypothesenbildung sollten dementsprechend nicht mit demselben Datensatz durchgeführt werden.

19 Engelmann, J., und Puntschuh, M. (2020). *KI im Behördeneinsatz: Erfahrungen und Empfehlungen*. Kompetenzzentrum Öffentliche IT und iRights.Lab.

20 Das Hauptziel besteht nicht darin, ein Zeitlimit zu erzwingen, sondern sich auf minimale Fortschritte zu konzentrieren und ständig Feedback einzuholen. In der Softwareentwicklung (und insbesondere im Bereich der Data Science) ist es schwierig, die Dauer von Aufgaben genau abzuschätzen.

Schließlich sollte das Team auf der Grundlage des Feedbacks seine Ziele für den nächsten Sprint formulieren. Diese Ziele werden wiederum in kleinere Arbeitsschritte unterteilt und mit kurzen Fristen versehen. Dieser Prozess sollte so lange fortgesetzt werden, bis ein zufriedenstellendes Endprodukt erreicht ist. Wenn auf dem Weg dorthin wesentliche Änderungen vorgenommen werden müssen (beispielsweise ein Wechsel der Datenquelle oder eine Neuformulierung des Anwendungsfalls), sollte der Austausch mit den Beteiligten gesucht werden. **Im Fokus sollte in jedem Fall weiter ein spezifischer, klarer Anwendungsfall stehen.**

Do**Legen Sie von Beginn an klare Zuständigkeiten für die Einbindung der Nutzer:innen fest.**

Die Nutzer:innen spielen bei der Entwicklung eines Datenprodukts eine entscheidende Rolle; wenn sie nicht verfügbar sind oder sich nicht einbringen, kann das den Fortschritt eines Projekts maßgeblich blockieren. Um die Umsetzung voranzutreiben und die Verantwortung zu bündeln, müssen deshalb klare Zuständigkeiten festgelegt werden. Wählen Sie auf der Nutzerseite jemanden als Hauptansprechperson für das Datenteam aus und strukturieren Sie die Zusammenarbeit entsprechend, etwa durch regelmäßige Treffen.

Befolgen Sie das KISS-Prinzip: „Keep it Simple and Straightforward“.

Konzentrieren Sie sich auf die Ziele des Projekts, die von den Endnutzer:innen vorgegeben werden. Achten Sie darauf, dass Sie nicht darüber hinausschießen. Eine zu komplexe Konstruktion kann dazu führen, dass Ihr Produkt für die vorgesehene Zielgruppe unbrauchbar wird. Müssen Sie sich zwischen verschiedenen Methoden entscheiden, sollten Sie die einfachere wählen, die von den Endnutzer:innen voraussichtlich besser verstanden wird. Greifen Sie nur dann zu komplexen Methoden, wenn diese wirklich erforderlich sind.

Dokumentieren Sie nicht nur den Code, sondern auch den Kontext.

Arbeiten Sie so, als ob jedes einzelne Teammitglied Sie bereits morgen verlassen könnte. Viele Tools und Datensätze werden in zukünftigen Projekten wieder gebraucht. Stellen Sie sicher, dass alle Arbeitsschritte dokumentiert werden, um spätere Mehrarbeit zu vermeiden. Erwägen Sie außerdem die Erstellung von „Info-Sheets“ für wichtige Datensätze, die nützliche Hinweise enthalten: Gibt es Besonderheiten bei der Datenquelle? Wie häufig wird sie aktualisiert? Wie hat das Team die Daten beschafft, und gibt es Einschränkungen bei der Nutzung?

Don't**(Scheinbare) Kleinigkeiten sind keine Nebensachen.**

Benutzerfreundlichkeit ist wichtig, aber oft sind den Nutzer:innen eines Produkts ganz andere Aspekte wichtig als den Entwickler:innen. Holen Sie deshalb die Erfahrungen der Endnutzer:innen ein und stellen Sie sicher, dass diese Ihr Produkt mehrmals testen. Benutzerfreundlichkeit, Benutzeroberfläche und verständliche Sprache können nur von den Benutzer:innen sinnvoll beurteilt werden. Nehmen Sie alle Rückmeldungen unvoreingenommen auf, auch wenn sie Ihnen „untechnisch“ erscheinen.

Zögern Sie nicht, externen Sachverstand hinzuzuziehen.

Gerade wenn Sie noch im Begriff sind, die Kapazitäten Ihres Teams aufzubauen, kann es inhaltliche und technische Kenntnisse geben, die Sie (noch) nicht abdecken. Externe Daten-Expert:innen, zivilgesellschaftliche Akteur:innen und spezialisierte Organisationen können diese Lücken auf unterschiedliche Weise schließen.²¹ Stellen Sie dabei sicher, dass von außen eingeholtes Spezialwissen und externe Fachkenntnisse in Ihrer Organisation verbleiben, damit Sie auch langfristig von diesen Partnerschaften profitieren.

Verhindern Sie, dass sich Data-Team-Mitglieder in Eventualitäten verlieren.

Machen Sie sich eine genaue Vorstellung davon, wie die Endnutzer:innen das Produkt verwenden möchten, und lassen Sie sich davon leiten. So geben Sie sich selbst eine klare Richtung für Ihre Bemühungen und kleinere Entscheidungen vor. Mitglieder Ihres Teams sollten sich nicht zu sehr mit Eventualitäten beschäftigen, also beispielsweise mit Funktionen, die verwendet werden *könnten* oder die sich aus dem Ausprobieren neuer Methoden ergeben *könnten*.

²¹ Kupi, M., Jankin, S., und Hammerschmid, G. (2022). *Data Science und KI in der Verwaltung*. Hertie School.



4. Evaluation

Wie sollten Data-Teams bei der Evaluierung ihrer Produkte vorgehen?

Im Vergleich zu anderen Softwareprodukten sind Fehler in Datenprodukten oft besonders schwer zu erkennen.²² Das liegt daran, dass sie nicht unbedingt die Funktionsfähigkeit des Produkts einschränken, sondern zu - subtilen oder ausgeprägten - Verzerrungen führen können. Nehmen wir das Beispiel eines Tools zur Priorisierung von Visumsanträgen: Wird hier mit einem verzerrten Datensatz gearbeitet, überträgt sich die Verzerrung auf die Ergebnisse, die dann möglicherweise eine ganze Bevölkerungsgruppe diskriminieren. Ein solcher Fehler richtet einen großen Schaden an, ist aber viel schwerer zu erkennen als ein simpler Programmfehler in der Benutzeroberfläche einer Software. Das Beispiel zeigt, wie wichtig es bei datengetriebenen Entscheidungshilfen ist, die Datengrundlage und den Kontext, aus denen das Tool entstanden ist, kritisch zu reflektieren. Werden Erkenntnisse aus Daten zu politischen Entscheidungen herangezogen, müssen die Entscheidungsträger:innen die Aussagekraft der Ergebnisse einordnen können. Das wiederum erfordert ein tiefes Verständnis sowohl der Methodik als auch des Kontexts, in dem die Evidenz generiert wurde. Dieses Verständnis zu schaffen ist eine der wichtigsten Aufgaben von Data Scientists im Policy-Bereich.

Staatliche Data-Science-Anwendungen können große Auswirkungen auf die ganze Bevölkerung haben. **Entsprechend hoch ist die Verantwortung, die Data-Science-Abteilungen tragen, wenn ihre Arbeit zur Grundlage für politische oder administrative Entscheidungen wird.** Nehmen wir beispielsweise KI-Systeme,²³ die in der Strafverfolgung oder bei anderen wesentlichen Dienstleistungen des Staates eingesetzt werden und potenziell in die Grundrechte von Menschen eingreifen: Sie werden im Entwurf für den AI Act der EU als „hohes Risiko“ eingestuft (die zweithöchste Kategorie nach dem „inakzeptablen Risiko“) und unterliegen strengen Verpflichtungen.²⁴

Um die notwendige Kontrolle zu gewährleisten, sollten Data-Science-Teams versuchen, ihre Arbeit einem vielfältigen Personenkreis zu erklären und breites Feedback einzuholen.

²² Siehe auch diese Sammlung von Fehlern oder Fallstricken in der ML-basierten Wissenschaft, wie z. B. fehlende Trainings-/Testsplits: <https://reproducible.cs.princeton.edu/#rep-failures>

²³ Data Science umschließt auch Methoden, die unter dem Sammelbegriff „Künstliche Intelligenz“ erfasst werden.

²⁴ Europäische Kommission (2022, Juni 07). [Vorschlag für einen Rechtsrahmen für künstliche Intelligenz.](#)

Datenprodukte sollten so nachvollziehbar und transparent wie möglich sein – die Verantwortung dafür liegt beim Data-Science-Team. Das gilt nicht nur für interne Projekte, sondern auch für die, die von externen Auftragnehmern durchgeführt werden.

Nach jedem Sprint und zum Schluss, wenn ein fertiges Produkt vorliegt, sollte es den wichtigsten Beteiligten vorgestellt werden. Zu diesem Kreis sollten zumindest einige der Endnutzer:innen gehören, die das Produkt verwalten oder mit ihm interagieren werden. Data-Science-Abteilungen sollten ihre Präsentation mit Blick auf die jeweilige Zielgruppe vorbereiten und strukturieren. Wie werden die Nutzer:innen mit dem Produkt umgehen? Wie viele technische Details müssen sie kennen?

Sinnvoll ist es beispielsweise, die Präsentation mit dem zu Grunde liegenden Problem oder der Leitfrage des Projekts zu beginnen. In der Folge kann erläutert werden, inwiefern das neue Produkt die Lösung darstellt (einschließlich der Methodik, soweit erforderlich²⁵). Dabei sollte so wenig Fachjargon wie möglich benutzt werden. Die Endnutzer:innen – die nicht unbedingt technisch geschult sind – müssen verstehen, wie das Tool funktioniert, und sich auf das Instrument verlassen können; zugleich müssen sie auch die Grenzen des Werkzeugs genau kennen. Diejenigen, die datenbasierte Erkenntnisse nutzen, müssen sich der möglichen Verzerrungseffekte und der begrenzten Aussagekraft bewusst werden.

Generell sollten Data-Science-Teams um so viel Feedback wie möglich bitten. Dabei sollte mit Fragen begonnen werden, die für die Nutzer:innen relevant sind; auch frühere Bedenken können aufgegriffen werden. Die Teilnehmenden sollten sich ernstgenommen fühlen und die Chance haben, auch allgemeinere Anmerkungen zu machen. Dabei sollte darauf geachtet werden, dass alle Vorschläge gleichermaßen gewürdigt und keine voreiligen Urteile gefällt werden. Das Feedback kann für weitere Schleifen im Designprozess genutzt werden sowie auch dafür, sich neue, präzise Entwicklungsziele zu stecken. Falls bereits ein finales Produkt vorliegt, sollte das Feedback in die langfristige Implementierung einfließen.

Data-Abteilungen sollten nach Abschluss eines Projekts die Wirkung und tatsächlich investierten Ressourcen mit ihren ursprünglichen Schätzungen und Vorhersagen abgleichen, um künftige Projekte besser beurteilen und priorisieren zu können.

²⁵ Dazu gehören relevante Parameter (z. B. die Falsch-Negativ-Rate), ihre Auswirkungen auf die Ergebnisse und ihre spezifischen Einstellungen.

Do**Gehen Sie offen mit den Stärken und Schwächen Ihrer Produkte um.**

Stellen Sie so viele Informationen wie möglich zur Verfügung, um Vertrauen in Ihr Produkt zu schaffen.²⁶ Mit welchen Datensätzen wurde es trainiert? Welches Modell wurde verwendet? Wie viel genauer ist das Modell im Vergleich zu früheren Vorhersagen? Ein transparenter Umgang ermöglicht eine breitere Auseinandersetzung mit den Stärken und Schwächen Ihres Produkts.

Lassen Sie die Risiken Ihres Produkts von verschiedenen Anwender:innen prüfen, bevor Sie es für einsatzbereit erklären.²⁷

Ein schlechtes Produkt sollte nicht in Betrieb genommen werden – selbst dann nicht, wenn es bereits vollständig entwickelt ist. Nehmen Sie sich immer die Zeit zu erörtern, welche Risiken es gibt. Schadet das Produkt womöglich einem bestimmten Bevölkerungssegment? Was könnte bei der Einführung schief gehen? Stellen Sie sicher, dass alle Betroffenen die Möglichkeit haben, sich zu dem Produkt zu äußern.²⁸

Vergleichen Sie Ihr Produkt stets mit der nächstbesten Alternative.

Während es in der Ideenfindungs-Phase darum geht, mögliche Anwendungsfälle ausfindig zu machen, sollten Sie bei der Evaluation konkret die Verbesserung benennen, die Ihr Tool mit sich bringt. Die Verbesserung sollte dabei immer im Vergleich zur nächstbesten Alternative betrachtet werden, nicht zum hypothetischen Idealfall. Wie viel genauer ist Ihr datenbasierter Prozess im Vergleich zum menschlichen Urteilsvermögen? Wie viele Arbeitsstunden werden eingespart? Diese konkreten Zahlen sind hilfreich, um eine realistische Erwartungshaltung zu entwickeln, sowohl im Team als auch bei den Nutzer:innen.

26 Empfehlung 9, Engelmann, J., und Puntschuh, M. (2020). *KI im Behördeneinsatz: Erfahrungen und Empfehlungen*. Kompetenzzentrum Öffentliche IT und iRights.Lab.

27 Central Digital und Data Office (UK) (2021, 31. März). *Make Things Accessible and Inclusive*.

28 Office for Artificial Intelligence (UK) (2020). *Guidelines for AI Procurement*.

Don't

Nicht nur technisches Feedback ist relevant.

Alle Aspekte des Nutzererlebnisses – ob technisch oder nicht – sind für die Gestaltung eines Produkts entscheidend. Während sich Fachleute zum Projektdesign oder zu den wissenschaftlichen Spezifikationen äußern, beurteilen andere die Benutzeroberfläche oder die Barrierefreiheit eines Produkts. Nehmen Sie sich die Zeit, alle Rückmeldungen, die Sie zu Ihrem Produkt erhalten, anzunehmen und zu verstehen.

Hüten Sie sich vor Betriebsblindheit - holen Sie externes Feedback ein.

Sowohl Ihre Nutzer:innen als auch Ihr Team haben wahrscheinlich den ein oder anderen blinden Fleck – Bereiche, die aufgrund festgefahrener Prozesse oder des Sunk-Cost-Irrtums falsch eingeschätzt oder ganz übersehen werden. Holen Sie deshalb regelmäßig externes Feedback ein – sei es von anderen Personen in Ihrer Organisation oder von externen Gutachter:innen –, um Ihre Arbeit aus einer anderen Perspektive zu sehen. Vielleicht finden Sie so eine effizientere Lösung für ein Problem oder stoßen im Zusammenhang mit Ihren Methoden auf ethische Fragen, die Sie sich zuvor nicht gestellt haben.

Vergessen Sie nicht, auch langfristig Ihre Wirkung zu messen.

Das Ziel eines Data-Science-Teams ist es, nützliche Produkte zu schaffen. Überprüfen Sie deren Nutzung deshalb am besten regelmäßig über einen längeren Zeitraum hinweg. Entwickeln Sie ein Verständnis dafür, wie das Produkt in der Praxis eingesetzt wird, um es zu verbessern. Begeben Sie sich auf Ursachenforschung, wenn eine Anwendung nicht mehr benutzt wird; mögliche Gründe sind etwa die Wartung oder Probleme mit Rechten und Besitzverhältnissen. Berücksichtigen Sie Ihre Erkenntnisse bei künftigen Projekten. Wenn das Produkt noch verwendet wird, welche Rückmeldungen gibt es? Wie kann das Produkt für die Nutzer:innen noch hilfreicher gemacht werden?



5. Teams

Wie baut man im öffentlichen Sektor starke Data-Science-Teams auf?

Wir haben im ersten Teil dieses Papiers beschrieben, dass für die Arbeit von Data-Science-Teams in Politik und Verwaltung einige Besonderheiten gelten: Datenlabore müssen in bestehende Behördenstrukturen und Verwaltungsprozesse integriert werden. Ihre Arbeit wird in vielen Fällen die Grundlage für politische und administrative Entscheidungen liefern, weshalb sie hohen ethischen Standards genügen muss. Vor diesem Hintergrund ist es besonders wichtig, die richtigen Talente zu rekrutieren und das Team nachhaltig zu entwickeln. Erschwert wird das Recruiting dadurch, dass in Data-Science-Abteilungen im öffentlichen Sektor im Vergleich zur Privatwirtschaft zumindest in der Anfangsphase keine Spitzentechnologien entwickelt und meist auch keine gleichwertigen Gehälter gezahlt werden. Gesucht werden deshalb Kandidat:innen, die intrinsisch motiviert sind und Wert auf eine Aufgabe mit gesellschaftlicher Wirkung legen. Zudem benötigen sie ein ausreichendes Verständnis des politischen Kontexts, in dem ihre Arbeit stattfindet.

Datenexpert:innen im öffentlichen Sektor müssen vor allem Übersetzungsarbeit leisten. Sie müssen die verschiedenen Welten verbinden und effektiv mit allen Seiten kommunizieren können. Während technische Fähigkeiten für Data-Science-Abteilungen natürlich unerlässlich sind, müssen sie auch den breiteren Kontext ihrer Arbeit verstehen und das Vertrauen anderer Abteilungen gewinnen können. Sie müssen in der Lage sein, Algorithmen und Code in reale politische Zusammenhänge einzuordnen und in den Verwaltungskontext zu übersetzen, oft auch für technisch weniger versierte Zielgruppen.

Die Projekte und Methoden der Datenabteilungen werden sich ändern, nicht aber das Ziel ihrer Arbeit. **Datenlabore sollten sich deshalb beim Recruiting auf wirkungsorientierte Kandidat:innen mit nachhaltiger Motivation konzentrieren.** Die besten Kandidat:innen sind diejenigen, die durch die Arbeit im öffentlichen Sektor etwas bewirken wollen und Daten als Mittel zu diesem Zweck verstehen. Kandidat:innen, die sich hauptsächlich auf technische Aspekte der Data Science konzentrieren wollen, könnten Verwaltungsstrukturen als erdrückend und ihre Arbeit als stark eingeschränkt empfinden.

Bedacht werden sollte auch, dass Data Science ein Feld ist, das ein breites Spektrum an Fähigkeiten und Kenntnissen umfassen kann – je nach Projekt kann sich der Qualifikationsbedarf rasch ändern. Personalverantwortliche sollten sich deshalb vor der Einstellung neuer Mitarbeitender klarmachen, was das Team braucht: Gibt es eine bestimmte Kompetenz, die das Team dringend benötigt, oder werden Generalist:innen gebraucht, die sich gut anpassen können? In jedem Fall sollten Flexibilität und Lernbereitschaft im Vordergrund stehen, sei es in Bezug auf neue Methoden oder inhaltliche Zusammenhänge.

Do

Stellen Sie sicher, dass die richtigen Leute von Ihrer Stellenausschreibung erfahren.

Viele Menschen arbeiten an der Schnittstelle von Politik und Data Science, wissen jedoch vielleicht nicht, dass es Ihre Datenabteilung gibt oder ob gerade Stellen frei sind. Bemühen Sie sich aktiv darum, potenzielle Interessent:innen zu erreichen, und betonen Sie die Bedeutung der Stelle. Richten Sie eine zentrale Website oder einen Newsletter ein, mit deren Hilfe offene Stellen im Bereich Technologie und Daten in Politik und Verwaltung bekannt gegeben werden können, und veröffentlichen Sie das Gesuch auch auf Stellenbörsen mit einem Schwerpunkt auf dem Gemeinwohl.²⁹

Werben Sie mit den Vorzügen der Arbeit in Ihrem Datenlabor.

Data-Science-Ausbildungspfade und Karriereoptionen waren lange Zeit auf den privatwirtschaftlichen Kontext ausgerichtet. Machen Sie klar, warum die Arbeit in Ihrer Regierungsbehörde eine gute Alternative ist. Betonen Sie die sinnstiftende Tätigkeit und den gemeinnützigen Charakter, und unterfüttern Sie Ihre Angaben mit Beispielen. Oder weisen Sie auf interessante Datensätze hin, mit denen man anderswo nicht arbeiten kann.

Vernetzen Sie Data-Science-Teams über verschiedene Ministerien hinweg.

Austauschmöglichkeiten ermöglichen nicht nur einen effizienten Wissenstransfer, sie machen das Stellenprofil auch attraktiver. Richten Sie Kommunikationskanäle wie regelmäßige Treffen, Chat-Kanäle und Hospitationen zwischen den Behörden und Ministerien ein. Bauen sie zudem zentrale Ressourcen und Archive auf, um Mehrarbeit zu vermeiden. Bieten Sie Schulungen an und integrieren Sie die Mitglieder von Data-Science-Abteilungen in der öffentlichen Verwaltung in eine

²⁹ Zum Beispiel [Good Jobs](#) oder [Gesines Jobtipps](#)

breitere Gemeinschaft von wirkungsorientierten Data Scientists. Zu diesem Zweck hat die britische Regierung beispielsweise einen regierungsübergreifenden Chat-Kanal und eine Mailingliste für Datenwissenschaftler:innen eingerichtet.³⁰

Don't

Vermeiden Sie falsche Erwartungen und eine „Innovation-First“-Mentalität.

Ausschreibungen sollten ein realistisches Bild davon zeichnen, was die Aufgaben sind. In Stellenanzeigen oder Vorstellungsgesprächen sollte nicht die Erwartung geweckt werden, dass Datenexpert:innen im öffentlichen Sektor hauptsächlich innovative Methoden oder neuartige Tools einsetzen. Das mag zunächst mehr Leute anziehen, ist aber nicht nachhaltig, wenn die Bewerber:innen später aufgrund unerfüllter Versprechen das Weite suchen.

Legen Sie nicht (nur) die für den öffentlichen Dienst üblichen Kriterien an.

Während sich die Behörden bei der Einstellung von Personal in der Regel auf traditionelle Qualifikationen konzentrieren (Universitätsabschluss, Dienstjahre usw.), haben Datenexpert:innen oft einen eher unkonventionellen Lebenslauf. Ihre Qualifikationen können aus Online-Kursen oder quantitativen Schwerpunkten diverser Studiengänge stammen, und Projekte und praktische Erfahrung sind für gewöhnlich wichtiger als der akademische Hintergrund. Anforderungen für die Position sollten daher nicht zu eng gefasst werden. Wenn Sie beispielsweise einen MINT-Abschluss (Mathematik, Informatik, Naturwissenschaft und Technik) als Voraussetzung angeben, kann dies qualifizierte Bewerber:innen abschrecken, die bereits über umfangreiche Erfahrung mit Data Science in politischen Bereichen verfügen.

Beugen Sie Konflikten mit angrenzenden Abteilungen vor.

In Organisationen, die so groß sind wie Ministerien, arbeiten möglicherweise mehrere Abteilungen – etwa IT- oder Statistikabteilungen – an ähnlichen Problemen oder Prozessen wie die Daten-Teams. Klären Sie also frühzeitig die Zuständigkeiten im Haus. Loten Sie die Möglichkeiten für Kooperationen aus und helfen Sie Ihren Mitarbeitenden, qualifizierte Ansprechpartner:innen innerhalb der Organisation zu finden.

³⁰ Im Vereinigten Königreich gibt es ein umfangreiches Community-Programm für Data Scientists des öffentlichen Sektors, das Schulungen, Treffen, Konferenzen und einen Slack-Chat umfasst. Mehr Informationen unter: <https://www.gov.uk/service-manual/communities/data-science-community>



Fazit

Die Einführung von Datenteams in den Bundesministerien bietet enorme Chancen für die Modernisierung der deutschen Verwaltung. Allerdings ist die Schaffung solcher Abteilungen kein Selbstläufer. Um zu gewährleisten, dass Datenteams kontinuierlich, nutzbringend und effektiv arbeiten können, muss sorgfältig darauf geachtet werden, wie sie eingesetzt werden und welche Projekte sie übernehmen.

Es mag verlockend sein, auf technologischen Fortschritt zu setzen, neueste Methoden zu implementieren oder sich mit digitalen Fähigkeiten zu schmücken. **Doch Investitionen in den digitalen Fortschritt werden sich langfristig nur auszahlen, wenn der Fokus auf Anwendbarkeit und Wirkung liegt.** Für den Anfang ist es deshalb wichtig, die Bedürfnisse der Behörden, ihr Arbeitsumfeld und ihre Abläufe zu verstehen, um beurteilen zu können, wo Datenprojekte die größte Wirkung erzielen können.

Um sicherzustellen, dass diese Ziele erreicht werden, sollte in jeder Phase des Entwicklungsprozesses die Kommunikation im Vordergrund stehen. Zudem sollte der Kontakt zu den Endnutzer:innen und anderen Beteiligten in allen vier Phasen des Designprozesses gehalten werden. Erwartungen sollten frühzeitig geklärt werden, um Frustrationen und Missverständnissen vorzubeugen.

Es kann nicht oft genug betont werden: Data Scientists tragen in der öffentlichen Verwaltung eine besondere Verantwortung, sowohl für die Daten, mit denen sie arbeiten, als auch für die Tools, die sie entwickeln. **Es ist deshalb von äußerster Wichtigkeit, dass sie verstehen, wie sich die von ihnen entwickelten Produkte in die rechtlichen, ethischen und administrativen Rahmenbedingungen der auftraggebenden Behörde oder Institution einfügen.** Regelmäßige Feedbackrunden und konsequente Produkttests sind unerlässlich.



Nachdem Data Science jahrelang eher in der Privatwirtschaft Anwendung fand, ist sie nun auch endlich in der öffentlichen Verwaltung auf dem Vormarsch. Wir gehen davon aus, dass sich dieses Feld in den kommenden Jahren stark entwickeln wird, und möchten unser Papier auch als Angebot zum Austausch verstanden wissen. Sollten Sie Fragen haben oder mit uns in den Dialog treten wollen, stehen wir gerne zur Verfügung. Damit sich Data Scientists aus NGOs, staatlichen Institutionen und Think Tanks, die sich mit politischen Fragestellungen befassen, besser vernetzen können, haben wir außerdem die Plattform „European Policy Data Science Network“³¹ ins Leben gerufen.

Für deutsche Bundesbehörden ist der Aufbau von Data Labs eine Chance, hochtalentiertere Data Scientists für die Arbeit im öffentlichen Sektor zu gewinnen. Data-Teams könnten schon in naher Zukunft Vorreiter einer besser ausgestatteten digitalen Regierung und Verwaltung in Deutschland sein. Es liegt in unser aller Interesse, das zu ermöglichen.

³¹ <https://policydatascientists.eu/>



Über die Stiftung Neue Verantwortung

Die Stiftung Neue Verantwortung (SNV) ist ein gemeinnütziger Think Tank, der an der Schnittstelle von Technologie und Gesellschaft arbeitet. Die Kernmethode der SNV ist die kollaborative Entwicklung von Politikvorschlägen und -analysen. Die Expert:innen der SNV arbeiten nicht allein, sondern entwickeln und testen Ideen gemeinsam mit Vertreter:innen aus Politik und Verwaltung, Technologieunternehmen, Zivilgesellschaft und Wissenschaft. Unsere Expert:innen arbeiten unabhängig von Interessengruppen und Parteien. Unsere Unabhängigkeit gewährleisten wir durch eine Mischfinanzierung, zu der viele verschiedene Stiftungen, öffentliche Mittel und Unternehmensspenden beitragen.

Über die Autor:innen

Pegah Maham ist Lead Data Scientist bei der Stiftung Neue Verantwortung, wo sie seit 2020 das Data-Science-Team aufbaut und Data Science in die Arbeit des Think Tanks integriert hat. Insbesondere beschäftigt sie sich mit der Frage, wie mit den Methoden der Data Science Trends in der Entwicklung Künstlicher Intelligenz und ihre gesellschaftlichen Folgen erfasst werden können. Sie ist außerdem Mitgründerin der Plattform „Policy Data Science Network“, die Datenwissenschaftler:innen in Politik und Verwaltung vernetzt. Zuvor hat Pegah Maham als Data Scientist in einem Start-Up im Bereich der erneuerbaren Energien gearbeitet. Sie hat Masterabschlüsse in Statistik (Humboldt Universität zu Berlin) und Data Science (London School of Economics).

Andy Wang ist Praktikant im Data-Science-Team der Stiftung Neue Verantwortung. Zuvor arbeitete Andy in der Forschungs- und Analyseabteilung der Generalstaatsanwaltschaft des Staates New York sowie in der Forschungs- und Datenabteilung der Legal Services Corporation, einer gemeinnützigen US-Rechtsberatungsgesellschaft. Andy Wang studiert Sozialwissenschaften, Philosophie und Informatik am Harvard College. Er beschäftigt sich insbesondere mit der Rolle von Daten in Politik und Verwaltung.



Impressum

Stiftung Neue Verantwortung e.V.
Beisheim Center
Berliner Freiheit 2
10785 Berlin

T: +49 (0) 30 81 45 03 78 80
F: +49 (0) 30 81 45 03 78 97
<https://www.stiftung-nv.de/en>
info@stiftung-nv.de

Design:
Make Studio
www.make-studio.net

Layout:
Alina Siebert
Tom Semmelroth



Dieser Beitrag unterliegt einer CreativeCommons-Lizenz (CC BY-SA). Die Vervielfältigung, Verbreitung und Veröffentlichung, Veränderung oder Übersetzung von Inhalten der Stiftung Neue Verantwortung, die mit der Lizenz „CC BY-SA“ gekennzeichnet sind, sowie die Erstellung daraus abgeleiteter Produkte sind unter den Bedingungen „Namensnennung“ und „Weiterverwendung unter gleicher Lizenz“ gestattet. Ausführliche Informationen zu den Lizenzbedingungen finden Sie hier: <http://creativecommons.org/licenses/by-sa/4.0/>