
Lost in Big Data? Mehr Mut zu Experimenten in der Forschung



Frauke von Bieberstein und Stefanie Jaussi

Zusammenfassung: Big Data ist auf dem Vormarsch – und die Möglichkeiten für die Forschung scheinen endlos. Die grossen Datenmengen erlauben Analysen, die in der Vergangenheit nicht denkbar waren. Doch ernstzunehmende Probleme können entstehen, wenn basierend auf Korrelationen kausale Zusammenhänge postuliert werden, die vielleicht gar nicht bestehen. Wir stellen Experimente als Möglichkeit vor, um kausale Zusammenhänge zu erkennen und zeigen unterschiedliche Anwendungen der experimentellen Wirtschaftsforschung auf: Im Feld, im Labor und in einer Kombination der beiden. Schliesslich argumentieren wir, dass Big Data in Verbindung mit experimentellen Forschungsdesigns eine spannende Kombination darstellen kann.



Stichworte: Big Data; Kausalität; Experimentelle Wirtschaftsforschung; Feldexperimente; Laborexperimente

Lost in Big Data? More courage to experiments in research

Summary: Big Data is on the rise – and the possibilities for research seem endless. The enormous amounts of data allow analyses that were not imaginable in the past. However, serious problems can arise when causal relationships are proposed based on correlations that may not even exist. We present experiments as a way to identify causal relationships and show different applications of experimental research: In the field, in the laboratory, and in a combination of the two. Finally, we argue that Big Data paired with experimental research designs can be an exciting combination.

Key words: Big Data; causality; experimental business research; field experiments; laboratory experiments

Das Zeitalter von «Big Data» – ein Paradies für die Wissenschaft?

Big Data ist cool – und wer «in» sein will ist dabei. Aktienkurse mit Hilfe von Tweets vorhersagen? Die Streckenplanung von Paketauslieferern in Echtzeit optimieren? Preise gemäss Markt- und Wettbewerbssituation dynamisch gestalten? Die Möglichkeiten von Big Data in der Wissenschaft scheinen endlos.

Zu den riesigen Datenbergen, die es bereits gibt, kommen jede Minute neue hinzu: Im Jahr 2019 wurden *in jeder Minute* 188 Millionen E-Mails sowie mehr als 18 Millionen Textnachrichten versendet und fast 4.5 Millionen Google-Suchanfragen getätigt. Vor dem Bildschirm verbringen wir aber noch weit mehr Zeit. Beispielsweise wurden 4.5 Millionen

YouTube-Videos geschaut, mehr als eine halbe Million Tweets gesendet und 400'000 Apps für noch mehr «Screen-Time» heruntergeladen (Domo 2019). Unzählige Klicks und rund 1 Million ausgegebene Dollar für Online-Einkäufe können ebenfalls auf die Minute hinuntergebrochen werden (Domo 2020). Während Sie diesen Abschnitt lesen, ist «Big Data» also gerade noch einmal ein grosses Stück gewachsen.

Big Data zeichnet sich durch ein immenses Volumen, eine sehr hohe Geschwindigkeit, in der die Daten entstehen und eine grosse Datenvielfalt aus. Diese drei beschriebenen «V's» von Big Data «*Volume, Velocity, and Variety*» erhielten schon vor fast zwei Dekaden viel Aufmerksamkeit, als Doug Laney die Diskussion um das Management von Daten mit seiner Definition massgeblich prägte. Daneben ist beispielsweise auch die *Veracity*, also die Wahrhaftigkeit der Daten wichtig, um Big Data erfolgreich nutzen zu können (Gandomi & Haider 2015).

Für Forschende scheint in Big Data ein Schatz zu liegen, den es nur zu heben gilt. So argumentieren beispielsweise die Editoren des *Academy of Management Journals*, dass sich die Managementforschung mit Big Data startklar mache für ein neues Zeitalter (George et al. 2016). Und tatsächlich, die grossen Datenmengen erlauben neue Arten von Analysen, die in der Vergangenheit nicht möglich waren. So können neue und feingliedrigere Datenpunkte erhoben werden. Beispielsweise kann eine Studie über Stress von Mitarbeitenden nicht nur Ergebnisse aus Befragungen enthalten, sondern auch biometrische Daten wie z.B. erhöhte Herzfrequenz oder Gesichtserkennungsmuster (George et al. 2016).

Aber liegt in Big Data das Allheilmittel? Und stellt Big Data, wenn es auf die Spur gebracht wird, nicht sogar die Wissenschaft gänzlich in Frage? Im Jahr 2008 veröffentlichte Chris Anderson, damals Chefredakteur von *Wired*, einen provokativen Artikel, in dem er ausrief, dass wir nur noch gute Daten bräuchten, und keine Theorien und Hypothesen mehr – das aber heisst, wir bräuchten keine Wissenschaft mehr. Denn mit genügend Daten würden die Zahlen für sich selbst sprechen. So plädierte Anderson dafür, dass Petabytes uns erlauben zu sagen «Korrelation ist genug». Wir können also aufhören, nach Modellen zu suchen. Wir können die Daten analysieren, ohne Hypothesen darüber aufzustellen zu müssen, was sie zeigen könnten. Gemäss Anderson soll Korrelation die Kausalität ersetzen – und vielleicht sogar die Wissenschaft insgesamt (Anderson 2008).

Wird die Wissenschaft wirklich obsolet? Fakt ist: heute steckt nicht nur die Unternehmenspraxis, sondern auch die Forschung mitten drin, im «Age of Big Data». Doch es ist Zeit, einen Schritt zurück zu machen und das «Big Picture» von Big Data zu betrachten.

Probleme mit Big Data: Der Umgang mit Korrelationen

Mit Big Data lassen sich zwar eine Vielzahl an Korrelationen finden, diese bedeuten aber nicht, dass es auch einen kausalen Zusammenhang gibt. Das heisst, wir beobachten das gemeinsame Auftreten von zwei Variablen, aber wir wissen nicht, ob A wirklich zu B führt. Beispielsweise fanden Aktienkurs-Analysten mit Hilfe von Big Data heraus, dass CEOs, die in Telefonkonferenzen mit Analysten höflicher waren, also häufiger Bitte und Danke sagten, im Nachgang eine bessere Kursperformance hinlegten (Wigglesworth 2018). Dazu wurden tausende von Mitschnitten dieser Telefonkonferenzen mit Hilfe von Artificial Intelligence auf ihre Sprache hin untersucht. Sollten Unternehmen also möglichst höfliche CEOs berufen oder umgekehrt ihre CEOs in Höflichkeit schulen, um die Kursperformance zu steigern? Auch wenn Höflichkeit meist nicht schadet, zeigte eine genauere Analyse der Daten, dass es sich hierbei um eine Scheinkorrelation handelt. Wenn das

Modell um weitere Variablen wie die generelle Marktentwicklung des Unternehmens in den Tagen nach der Telefonkonferenz erweitert wurde, hatte die Höflichkeit des CEOs keinen Effekt mehr auf die Kursperformance.

Das Problem ist, dass Big Data besonders anfällig ist für derartige Scheinkorrelationen: Forscher zeigten mittels mathematischer Berechnungen, dass sehr grosse Datenbanken besonders häufig willkürliche Korrelationen enthalten. Diese Korrelationen treten gerade deshalb auf, weil die Daten so umfangreich sind. So finden sich solche Korrelationen beispielsweise auch in grossen zufällig generierten Datenbanken (Calude & Longo 2017). Während manche von ihnen sehr einfach erkannt werden können (z.B. korreliert die Butterproduktion in Bangladesch stark mit der Performance des US-Aktienmarktes, Wigglesworth 2018), sind andere Scheinkorrelationen «glaubwürdiger» und damit schwerer zu entlarven.

Ein ähnlich gelagertes Problem kann auftreten, wenn man beispielsweise die Auswirkungen von Homeoffice untersuchen möchte. Viel wurde darüber geschrieben und spekuliert, wie sich die Produktivität der Mitarbeitenden verändert, wenn von zuhause aus gearbeitet wird, eine Fragestellung, die im Zuge der Corona-Pandemie in den Fokus gerückt ist. Vernetzte Zusammenarbeit und die Digitalisierung der Arbeit führen zu rapide wachsenden Datenmengen, die es Unternehmen ermöglichen, auch bei einem Wechsel des Arbeitsortes Produktivitätskennzahlen leichter zu erheben. Aber auch hier gilt es, Korrelation und Kausalität zu unterscheiden. Wenn beispielsweise alle Mitarbeitenden aufgrund einer Pandemie ins Homeoffice gehen und sich ein Absinken der Produktivität zeigt – liegt es dann am Homeoffice? Da sich gleichzeitig viele andere Dinge verändert haben, wie die Nachfrage, das Angebot an Kinderbetreuung oder die Gesundheit der Mitarbeitenden, ist ein solcher Rückschluss nicht möglich. Ähnlich sieht es aus, wenn sich ausserhalb einer Pandemie ein Unternehmen entscheidet, alle Mitarbeitenden, die dies möchten, von zuhause aus arbeiten zu lassen. Angenommen, das Unternehmen stellt fest, dass sich die Produktivität dieser Mitarbeitenden daraufhin erhöht. Bedeutet dies, dass das Unternehmen von nun an alle Mitarbeitenden ins Homeoffice schicken sollte? Auch ein solcher Rückschluss ist nicht zulässig, da beide Gruppen an Mitarbeitenden sich unterscheiden könnten. Während die einen gerne ins Homeoffice gehen wollten, vielleicht um Arbeitswege einzusparen oder weil sie zuhause gute Bedingungen dafür vorfinden, hatten sich die anderen Mitarbeitenden bewusst dagegen entschieden. Wenn nun diese zweite Gruppe auch von zuhause arbeiten muss, ist es gut möglich, dass ein allfälliger Produktivitätsanstieg bei ihnen geringer ausfällt oder die Produktivität sogar sinkt. Zusätzlich können sich die Gruppen nicht nur in ihrer Bereitschaft unterscheiden, von zuhause zu arbeiten, sondern auch in anderen wichtigen Charakteristika, die für die Produktivität im Homeoffice eine wichtige Rolle spielen können. Beispielsweise könnten sich nur besonders motivierte oder erfahrene Mitarbeitende für das Homeoffice entscheiden. Wenn sich dann ein Effekt zeigt, ist nicht klar, ob er am Homeoffice liegt oder an der Motivation oder Erfahrung der Mitarbeitenden.

Zusammenfassend besteht somit ein grosses Problem, wenn basierend auf Korrelationen kausale Beziehungen zwischen Variablen postuliert werden, die eigentlich gar nicht vorhanden sind. Denn die Managementforschung und das Management sind in den allermeisten Fällen an Kausalitäten interessiert. Fast immer geht es um die Frage: Wenn ich A ändere (z.B. das Führungsverhalten, das Officelayout, die Marketingkampagne), kann ich dann damit rechnen, dass ich B positiv beeinflusse (z.B. die Leistung und Zufriedenheit der Mitarbeitenden oder Umsatz und Gewinn)?

Experimentelle Forschung: Kausalitäten erkennen

Experimentelle Forschung liefert den sogenannten «Gold Standard», um kausale Zusammenhänge aufzudecken. Aber was zeichnet ein Experiment aus und kann es in der Wirtschaftsforschung wirklich sinnvoll eingesetzt werden? Im Folgenden wollen wir diesen Fragen anhand einiger Beispiele auf den Grund gehen.¹ So wollten Forschende die Auswirkungen des Homeoffice auf die Produktivität von Mitarbeitenden analysieren (Bloom *et al.* 2015). Sie suchten ein Unternehmen, das sich mit der Frage beschäftigte, ob es den Angestellten ein Arbeiten von zuhause ermöglichen sollte. Fündig wurden sie bei Ctrip, dem grössten chinesischen Online-Reisebüro, das China-weit Call-Center betreibt. Dort befürchtete das Management, dass beim Arbeiten von zuhause deutlich weniger gearbeitet würde. Man beschloss, diese Frage in einem gemeinsamen Feldexperiment im Call-Center in Shanghai zu untersuchen. Dazu wurden zunächst die Mitarbeitenden gefragt, ob sie gerne von zuhause aus arbeiten würden. Diejenigen, die sich freiwillig für das Homeoffice meldeten, wurden dann zufällig in zwei Gruppen eingeteilt, wobei allen Mitarbeitenden bewusst war, dass das Los entschied: Die eine Gruppe wurde beauftragt, während 9 Monaten im Homeoffice zu arbeiten, während die andere Gruppe über den gleichen Zeitraum ihrer Arbeit wie bisher im Call-Center nachging. Der Erfolg war frappant: Im Homeoffice nahmen die Mitarbeitenden mehr Anrufe entgegen, waren seltener krank und machten sogar weniger Pausen, als die Mitarbeitenden, die nicht von zuhause arbeiten konnten. Bei diesen Ergebnissen wenig überraschend, wurde auch ein Anstieg der Arbeitszufriedenheit gemessen (Bloom *et al.* 2015).

Das Beispiel zeigt wichtige Vorgehensweisen in der experimentellen Forschung: Es werden (mindestens) zwei Gruppen gebildet, die sich im Idealfall nur in einer Hinsicht unterscheiden: eine Gruppe wird dem Treatment ausgesetzt (die Möglichkeit von zuhause zu arbeiten, eine Weiterbildung, eine neue Form der Leistungsvergütung, etc.) und die andere nicht. Letztere dient als Kontrollgruppe für den Vergleich zur Treatmentgruppe. Damit soll ausgeschlossen werden, dass andere Einflussfaktoren ausserhalb der untersuchten Variable eine Rolle spielen. Zudem erfolgt die Zuteilung zu den Gruppen randomisiert, so dass bei einer genügend grossen Gruppe alle weiteren Faktoren ähnlich zwischen den Gruppen verteilt sind. Zum Beispiel kommen nicht nur hoch motivierte Mitarbeitende in die Treatmentgruppe. Solche Feldstudien sind ein ausgezeichnetes Instrument für Forschende, die kausale Zusammenhänge untersuchen und gleichzeitig in einem möglichst realitätsnahen Setting arbeiten wollen.

Das Beispiel zum Homeoffice zeigt spannende Ergebnisse aus einem Umfeld – dem Call-Center – in welchem Produktivität sehr einfach messbar ist und die Arbeit keine hohe Kreativität und wenig Austausch im Team erfordert. Es gibt somit noch viel Raum für weitere interessante Feldforschung in anderen Settings zu diesem Thema. Allerdings zeigt das obige Beispiel auch Probleme, die bei der Durchführung im Feld entstehen können. Ein wichtiger Punkt bezieht sich auf die Auswahl der Mitarbeitenden, die für die «Homeoffice-Intervention» in Frage kommen. Aus Unternehmenssicht kann es sinnvoll sein, den Einfluss des Homeoffice auf die Produktivität nur für diejenigen Personen zu überprüfen, die gerne von zuhause aus arbeiten wollen. Um den Effekt von Homeoffice auf die gesamte Produktivität messen zu können, wäre ein Setting zu bevorzugen, in

¹ Für weiterführende Unterlagen zur experimentellen Forschung verweisen wir auf das Handbuch von Kagel & Roth (2016).

dem alle Mitarbeitenden des Call-Centers zufällig zur Kontroll- oder zur Treatmentgruppe zugeteilt werden. Zudem sollten im Idealfall die Teilnehmenden nicht wissen, ob sie zur Treatment- oder zur Kontrollgruppe gehören, da alleine dieses Wissen das Verhalten beeinflussen kann. So könnten beispielsweise die Personen, die trotz eigenem Wunsch nicht ins Homeoffice durften, aus Enttäuschung ihre Leistung heruntergefahren haben. Die Forscher begegnen diesem Einwand, indem sie etwa zeigen, dass in dieser Gruppe die Leistung nicht abgesunken, sondern in der Treatmentgruppe gestiegen ist. Außerdem vergleichen sie die Treatmentgruppe mit Mitarbeitenden aus anderen Call-Centern und zeigen, dass auch bei diesem Vergleich das Homeoffice einen Anstieg der Produktivität verzeichnet. In Feldexperimenten, die gemeinsam mit Unternehmen gemacht werden, können somit gewisse Kompromisse bei der Durchführung notwendig sein (beispielsweise, dass nur Personen ins Homeoffice gehen, die das auch möchten), die dann weitergehende Analysen erfordern.

Diese Problematik kann mit Hilfe von Laborexperimenten umgangen werden. Hier werden die Teilnehmenden, häufig Studierende, ins Labor eingeladen und gemäss ihren Entscheidungen im Experiment entlohnt. Dadurch haben die Forschenden die volle Kontrolle über das Setting. Zudem ist die Managementforschung häufig mit Fragestellungen konfrontiert, die nur schwer, oder nicht isoliert in der Praxis untersucht werden können. Hierfür kann es sich anbieten, mit einem Laborexperiment zu arbeiten, da hier auch Variablen gemessen werden können, die im Feld nur schwer greifbar sind (zum Beispiel betrügerisches Verhalten oder individuelle Performance bei starken Variationen in der Lohngestaltung). Außerdem können Ideen vorab geprüft werden, bevor sie im Feld konkret ausprobiert werden.

Im Beispiel des Homeoffice bietet Big Data Unternehmen die Möglichkeit, ihre Mitarbeitenden umfangreich zu überwachen – und so beispielsweise den Kontrollverlust durch den Wechsel des Arbeitsorts wieder auszugleichen. Im Falle des Call-Centers hat sich hierdurch wenig geändert, da schon vorher die Produktivität sehr genau gemessen wurde. Aber kann in anderen Settings vielleicht die Kontrolle selbst einen negativen Einfluss auf die Produktivität ausüben? Zum Beispiel, weil sie signalisiert, dass das Unternehmen den Mitarbeitenden nicht vertraut? Den möglichen Kosten von Kontrolle gehen die beiden Forscher Armin Falk und Michael Kosfeld in einem spannenden Laborexperiment nach. In ihrem Experiment arbeiten jeweils zwei Teilnehmende zusammen, einer in der Rolle des Arbeitgebers und einer in der Rolle des Arbeitnehmers. Der Arbeitgeber kann seinen Arbeitnehmer kontrollieren, indem er eine minimale Leistungsanforderung einführt, die dieser in jedem Fall zu erfüllen hat. Er hat aber auch die Möglichkeit, keine Kontrolle einzuführen – und stattdessen darauf zu vertrauen, dass der Arbeitnehmer von sich aus produktiv sein wird. Die Ergebnisse dieses Experiments zeigen, dass Kontrolle durchaus versteckte Kosten mit sich bringt. Denn die meisten Arbeitnehmer reagieren mit reduzierter Leistung auf die Entscheidung des Arbeitgebers, den Kontrollmechanismus einzuführen. Angesichts dieser versteckten Kosten, wären die Arbeitgeber besser gestellt, würden sie den Arbeitnehmern vertrauen. Die meisten Arbeitgeber scheinen diesen nachteiligen Effekt zu antizipieren und legen ihren Arbeitnehmern keine Mindestanforderungen auf (Falk & Kosfeld 2006).

Bei manchen Fragestellungen kann auch eine Kombination der beiden vorgestellten experimentellen Ansätze spannend sein, nämlich, das Labor ins Feld zu bringen. Das bedeutet, ein typisches Laborexperiment nicht mit Studierenden durchzuführen, sondern

mit Gruppen an Teilnehmenden, die für die spezifisch untersuchte Frage von besonderem Interesse sind. In einem unserer Experimente (*von Bieberstein, Jaussi & Vogel 2020*) brachten wir unser mobiles Labor in ein Unternehmen, das in der Gebäudereinigung tätig ist. Wir wollten herausfinden, warum Frauen zu einem viel grösseren Anteil als Männer in einem solchen typischen Niedriglohn-Sektor tätig sind. Insbesondere wollten wir die Hypothese untersuchen, ob Frauen eine geringere Bereitschaft haben, in einem unsicheren Umfeld eine neue Herausforderung anzunehmen.² Dies könnte erklären, wieso der Karrierepfad von Frauen anders verläuft als der von Männern. Dabei konzentrierten wir uns auf den unteren Teil des Lohnspektrums, wo viele Frauen verharren, und nicht, wie sonst in der Forschung häufig der Fall, auf das obere Management. Wir luden die Reinigungsmitarbeiterinnen und -mitarbeiter des Partnerunternehmens in unser Labor ein, wo sie für eine Aufgabe, die kein Vorwissen erfordert, den Schwierigkeitsgrad wählen konnten. In der Kontrollgruppe konnte nur zwischen zwei Schwierigkeitsniveaus gewählt werden. Hier zeigten sich Männer viel stärker geneigt, eine kniffligere, aber auch besser bezahlte Aufgabe anzugehen, als Frauen, die eher eine bereits bekannte, einfachere Aufgabe wählten. Als wir jedoch in der Treatmentgruppe mehrere Schwierigkeitsgrade anboten, verzeichneten wir einen beeindruckenden Anstieg bei den Frauen – nun gingen viel mehr von ihnen eine Herausforderung ein. Diese Studie zeigt somit mögliche Anknüpfungspunkte für geschlechterspezifische Mentoring-Programme oder Weiterbildungen.

Bei allen wissenschaftlichen Studien und Datenerhebungen, ungeachtet des effektiven Datenumfangs, haben Forschende eine grosse Verantwortung. Sie müssen dafür sorgen, dass ethische Standards zwingend eingehalten sind. Wenn sich Teilnehmende zu einer wissenschaftlichen Studie im Labor anmelden, sollten sie über die Verarbeitung der gesammelten Daten und den Datenschutz informiert werden und eine Einverständniserklärung abgeben. Bei Untersuchungen im Feld wissen die Teilnehmenden häufig nicht, dass sie Teil eines Forschungsprojekts sind und sind daher besonders schutzbedürftig. Für alle wissenschaftlichen Studien müssen deshalb universitätsinterne oder externe Ethikkommissionen Forschungsanträge mit detaillierten Beschreibungen des geplanten Forschungsprojekts prüfen. Es muss gewährleistet sein, dass Personen keine Nachteile durch ihre Teilnahme am Forschungsprojekt erfahren. Zudem besteht die Möglichkeit, Forschungsprojekte vorab zu registrieren. Dieses Vorgehen verbessert die Transparenz und ermöglicht hypothesegeleitetes Forschen. Auch kann hiermit unethisches Verhalten in der Wissenschaft eingedämmt werden.

Experimente und Big Data: Eine lohnenswerte Kombination

Experimente erlauben es Forschenden also, kausale Zusammenhänge zu erkennen und Variationen systematisch zu testen. Und hier schliesst sich der Kreis: Die Kombination von Experimenten mit Big Data kann zu spannenden neuen Erkenntnissen führen. Die grossen Internetunternehmen machen es vor: Sie setzen bereits seit Jahren auf experimentelle Designs, um mit sogenannten «AB-Testings» systematisch zu beurteilen und zu vergleichen, welchen Effekt eine geplante Veränderung mit sich bringt. Das Beispiel der Suchmaschine Bing unterstreicht dabei die wirtschaftliche Bedeutung von solchen Untersuchungen. So

2 Ein spannendes Laborexperiment mit Studierenden als Teilnehmenden, das sich mit Geschlechterunterschieden im Wettbewerbsverhalten beschäftigt, wird im Artikel von *Osterloh & Fong (2021)* in diesem Sonderband beschrieben.

hatte im Jahr 2012 ein Mitarbeiter von Bing die Idee, die Anzeigenüberschriften der Suchmaschine zu optimieren. Die Umsetzung erforderte nicht viel Aufwand, wurde jedoch länger herausgezögert, bis zu dem Moment, als ein Ingenieur ein einfaches, kontrolliertes Online-Experiment aufsetzte. In diesem wurden zwei Bedingungen (A/B) erstellt und den Besuchern der Website nach dem Zufallsprinzip eingeblendet. Der AB-Test führte innerhalb von nur wenigen Stunden zu einem internen Alarm: Die verzeichneten Einnahmen waren so hoch, dass normalerweise ein Fehler signalisiert worden wäre. In diesem Fall ergaben jedoch die Auswertungen, dass allein durch die Anpassungen der Überschrift der Umsatz um 12 % gesteigert wurde, ohne dabei das Benutzererlebnis zu verschlechtern. Aufgrund des sauberen Testdesigns konnte innerhalb kürzester Zeit der Online-Auftritt massiv verbessert und optimiert werden (Kohavi & Thomke 2017). Forschende könnten ähnliche Kombinationen von experimenteller Methode und Big Data nutzen, um theoriegeleitete Hypothesen zu testen.

Auch wenn dieser Artikel viel Werbung für die experimentelle Methode enthält, sind wir uns natürlich bewusst, dass Experimente nicht immer und überall möglich sind. Wir wissen den Wert anderer empirischer Methoden ebenso zu schätzen. Trotzdem möchten wir eine Lanze brechen für mehr Mut zu Experimenten, wo diese möglich sind.

Literaturverzeichnis

- Anderson, C. (2008). The end of theory: The data deluge makes the scientific method obsolete. *Wired*, URL: http://archive.wired.com/science/discoveries/magazine/16-07/pb_theory, 11.12.2020.
- von Bieberstein, F., Jaussi, S. & Vogel, C. (2020). Challenge-seeking and the gender wage gap: A lab-in-the-field experiment with cleaning personnel. *Journal of Economic Behavior & Organization*, 175, 251–277.
- Bloom, N., Liang, J., Roberts, J., & Ying, Z. J. (2015). Does working from home work? Evidence from a Chinese experiment. *The Quarterly Journal of Economics*, 130(1), 165–218.
- Calude, C. S., & Longo, G. (2017). The deluge of spurious correlations in big data. *Foundations of Science*, 22(3), 595–612.
- Domo (2019; 2020). Data never sleeps 7.0 / 8.0. URL: https://www.domo.com/learn/data-never-sleeps-7# / <https://www.domo.com/learn/data-never-sleeps-8>, 11.12.2020.
- Gandomi, A., & Haider, M. (2015). Beyond the hype: Big data concepts, methods, and analytics. *International Journal of Information Management*, 35(2), 137–144.
- George, G., Osinga, E. C., Lavie, D. & Scott, B. A. (2016). Big data and data science methods for management research. *Academy of Management Journal*, 59(5), 1493–1507.
- Kagel, J. H., & Roth, A. E. (2016). *The handbook of experimental economics*, vol. 2, Princeton University Press.
- Kohavi, R., & Thomke, S. (2017). The surprising power of online experiments. *Harvard Business Review*, 95(5), 74–82.
- Osterloh, M. & Fong, M. (2021). Wir würfeln einen Chef oder eine Chefin! *Die Unternehmung*, 75(2), 139–145.
- Wigglesworth, R. (2018). Spurious correlations are kryptonite of Wall St's AI rush. In: *Financial Times*, URL: <https://www.ft.com/content/f14db820-26cd-11e8-b27e-cc62a39d57a0>, 11.12.2020.

Frauke von Bieberstein, Prof. Dr., ist Institutsdirektorin und Professorin am Institut für Organisation und Personal der Universität Bern.

Anschrift: Universität Bern, Institut für Organisation und Personal, CH-3012 Bern, Tel.: +41 31 631 54 64, E-Mail: frauke.vonbieberstein@iop.unibe.ch

Stefanie Jaussi, Dr., ist Oberassistentin am Institut für Organisation und Personal der Universität Bern.

Anschrift: Universität Bern, Institut für Organisation und Personal, CH-3012 Bern, Tel.: +41 31 631 54 63, E-Mail: stefanie.jaussi@iop.unibe.ch