

DER BETRIEBSWIRT

Korrelationen müssen auch kausal sein

Große Datenmengen sind nicht per se von Wert, nur die richtige Analyse von Daten und das Ziehen der richtigen Schlussfolgerungen machen Daten wertvoll.

Von Martin Spindler, Victor Chernozhukov und Ye Luo

Bei der Datenanalyse geht es in der Regel darum, entweder Vorhersagen zu treffen oder kausale Schlussfolgerungen zu ziehen. Bei der Vorhersage verwenden Algorithmen des maschinellen Lernens Eingabedaten, um Parameter oder Modelle zu schätzen, die für Vorhersagen neuer Beobachtungen beziehungsweise Daten verwendet werden können. Typische Prognoseaufgaben in Geschäftsanwendungen sind die Vorhersage finanzieller Größen im Finanzwesen (Wie hoch ist die Wahrscheinlichkeit, dass ein bestimmtes Unternehmen im nächsten Jahr insolvent anmelden muss?), die Risikoklassifizierung oder Risikobewertung in Versicherungen oder Nachfrageschätzung im Marketing (Wie hoch ist die Wahrscheinlichkeit, dass ein Konsument ein neues Produkt kauft?). Methoden des maschinellen Lernens, wie Lasso, Boosting, Random Forest, Neuronale Netze und Deep Learning oder Ensemble Methoden, haben sich als sehr leistungsfähig für voraussagende Aufgaben erwiesen. Großbanken wie JP Morgan oder die Chinese Construction Bank verwenden diese Methoden zur Beurteilung der Bonität von Kreditnehmern (Credit Scoring). Unternehmen wie Google und Amazon wenden diese im Marketing an.

Das zweite Ziel der Datenanalyse ist die sogenannte kausale Inferenz (Schlussfolgerung aufgrund ursächlicher Zusammenhänge). Dieses Ziel soll nun ausführlicher erläutert werden, weil es weniger bekannt und erforscht ist als die Vorhersage, aber entscheidend für den intelligenten Umgang mit Daten ist. Zur Veranschaulichung folgendes Beispiel: Angenommen, wir finden eine Korrelation zwischen Lungenkrebs und dem Tragen eines Feuerzeugs. Dies bedeutet, dass Menschen, die ein Feuerzeug tragen, mit einer höheren Wahrscheinlichkeit Krebs haben. Hier ist es ganz offensichtlich, dass kein kausaler Zusammenhang besteht, sondern Raucher häufiger ein Feuerzeug bei sich haben und Rauchen Krebs verursacht, nicht aber das Tragen eines Feuerzeugs. Ohne medizinisches Vorwissen ist es aber fast unmöglich, dies herauszufinden, wenn nur die Daten ohne weitere Information gegeben sind.

Warum interessieren wir uns für kausale Mechanismen? Angenommen, der Gesundheitsminister möchte die Lungenkrebsrate verringern und schlägt vor, Feuerzeuge zu verbieten. Hier wird ein einfaches Verbot natürlich nicht funktionieren, aber oft werden Entscheidungen in Politik und Wirtschaft nur aus Korrelationen abgeleitet, ohne die kausalen Mechanismen zu verstehen. Bei der kausalen Inferenz möchten wir den zugrunde liegenden Mechanismus verstehen, um die Wirkung von Interventionen beurteilen zu können. Das Beispiel zeigt auch, dass kausale Inferenz in der Regel ein subtileres Problem ist als Vorhersagen. In dem Beispiel kann es immer noch möglich sein, gute Vorhersagen für Lungenkrebs zu erhalten, nur basierend auf der Beobachtung, ob jemand ein Feuerzeug mit sich trägt, wenn das Tragen eines Feuerzeugs und Rauchen stark korreliert sind. Somit kann die Vorhersage trotzdem immer noch funktionieren.

Im Geschäftsleben gibt es viele Probleme, bei denen kausale Inferenz eine Schlüsselrolle spielt. Die Bereiche Prediction Analytics/Business Analytics, die sich momentan in Unternehmen großer Beliebtheit erfreuen, produzieren letztlich eine Unzahl an Vorhersagen und (Schein-)Korrelationen, die häufig zu falschen oder schlechten Entscheidungen führen und somit die Erwartungen nicht erfüllen. Ein wichtiges Beispiel hierfür ist

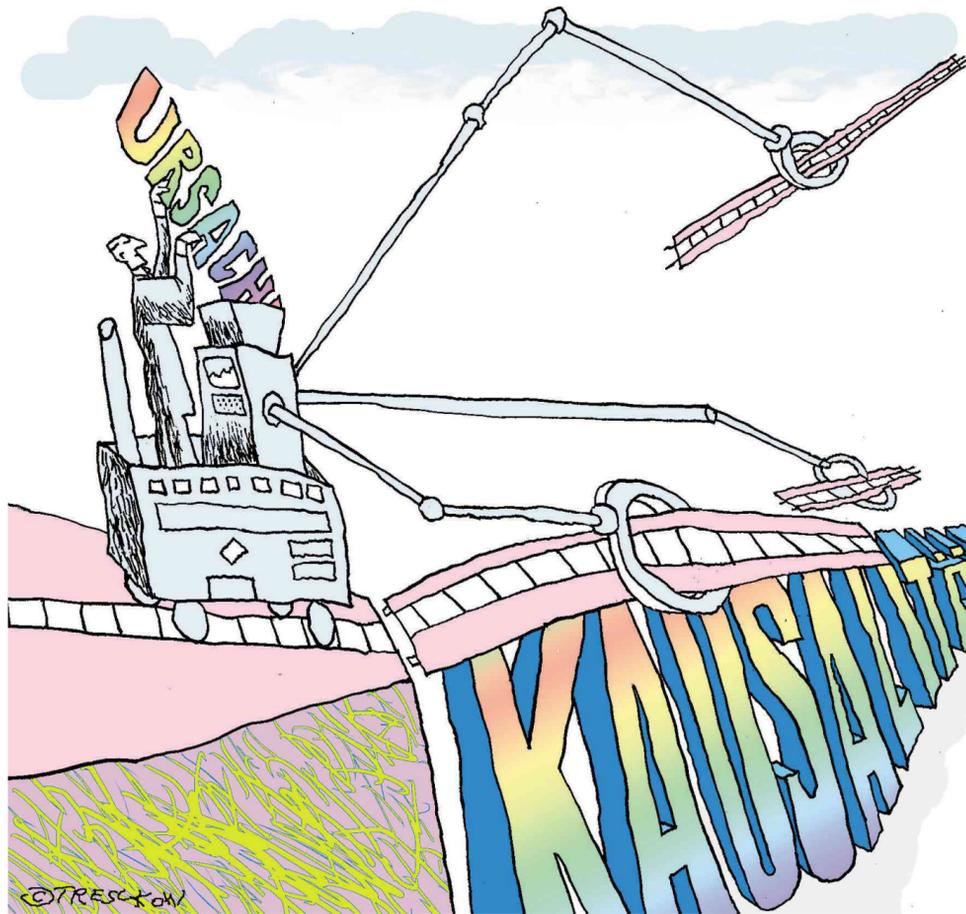


Illustration Peter von Tresckow

die Preisgestaltung (Pricing). Ein zentrales Thema nämlich in der Volkswirtschaftslehre seit den Anfangstagen ist die Schätzung der Nachfrage und wie sich die Nachfrage mit dem Preis ändert. Dies ist für Unternehmen sehr wichtig, um gewinnmaximierende Preise festlegen zu können (Dynamic Pricing). Hier kommt es darauf an, den (kausalen) Effekt des Preises auf die Nachfrage abzuschätzen, um die Nachfrage unter verschiedenen Preisplänen bewerten zu können. Klassische Vorhersagemodelle sind dafür aber ungeeignet.

Ein anderes Beispiel ist die Auswirkung einer Marketingkampagne auf Klickraten, Konversionsraten und schließlich Gewinn. Ziel hier ist es, den isolierten kausalen Effekt der Kampagne auf die interessierende Ergebnisvariable (Gewinn, Umsatz) zu schätzen. Die Beispiele zeigen, wie wichtig es ist, kausale Effekte zu schätzen. Aber wie können diese Schätzungen nun anhand von Daten durchgeführt werden?

Ein sehr populärer Ansatz in der Wissenschaft für kausale Inferenz ist das randomisierte Kontrollexperiment (im Englischen randomized control trials oder RCT) (in der Betriebswirtschaft als A/B-Test bekannt). Um einen kausalen Effekt zu identifizieren, werden die Teilnehmer nach dem Zufallsprinzip in zwei Gruppen eingeteilt: die Kontrollgruppe und die Behandlungsgruppe. Wie der Name andeutet, erhalten die Individuen in der Behandlungsgruppe die „Behandlung“ (Treatment), während die Einzelheiten in der Kontrollgruppe nicht behandelt werden. Anschließend werden beide Gruppen für die Zeit des Experiments beobachtet und die Differenz zwischen dem Durchschnitt der Ergebnisse in beiden Gruppen gibt dann den kausalen Effekt (Behandlungseffekt) an. Kommen wir zu unserem Beispiel mit dem Feuerzeug zurück: Man könnte eine Studie mit 100 Teilnehmern durchführen, die zufällig in zwei Gruppen aufgeteilt werden. Eine Gruppe (die Behandlungsgruppe) wird angewiesen, ein Feuerzeug zum Beispiel für ein Jahr zu tragen, und die andere Gruppe (die Kontrollgruppe) sollte kein Feuerzeug für ein Jahr tragen. Nach dem Zeitraum wird die Krebsrate beider Gruppen verglichen und hier erwarten wir kei-

ne systematischen Unterschiede zwischen beiden Gruppen.

RCTs sind seit langem der Standard in Medizin und Biologie. In wirtschaftlichen Anwendungen ist es aufgrund der damit verbundenen Kosten viel schwieriger, solche Experimente durchzuführen. Für wichtige Fragen können (trotz der Kosten) große Experimente durchgeführt werden. Eine neue Blüte von randomisierten Experimenten wird durch Internet-Anwendungen getrieben. Das Internet ermöglicht weniger kostenintensive Experimente und Tech-Unternehmen wie Amazon, Google und Microsoft nutzen laufend solche Experimente. Das Geschäftsmodell von Internetunternehmen beruht letztlich auf der intelligenten Nutzung der durch die Benutzer generierten beziehungsweise bereitgestellten Daten, um für sie maßgeschneiderte Angebote bereitzustellen. Führt das neue Empfehlungssystem zu mehr Verkäufen? Welches Preismodell maximiert den Gewinn?

Viele Geschäftsmodelle, wie die von Uber oder Airbnb, basieren ausschließlich auf dem Internet und ermöglichen es, dem Unternehmen, Preise dynamisch festzulegen („dynamische Preisgestaltung“). Kunden, die die Website besuchen, werden nach dem Zufallsprinzip dem alten oder neuen System zugeordnet. Dabei werden die Ergebnisse aufgezeichnet, die eine kausale Interpretation ermöglichen. In diesen Anwendungen ist es auch leicht, zusätzliche Informationen zu sammeln, neben der Zielvariablen (dem „outcome“, zum Beispiel Verkäufe) und der Behandlungsvariablen (altes/neues System), zum Beispiel welche Artikel angeschaut wurden und für wie lange sowie vorherige Einkäufe. Diese Informationen können wertvoll sein, um den Behandlungseffekt präziser zu schätzen. Eine präzisere Schätzung führt wiederum zu verlässlicheren Entscheidungen.

Für den Fall, dass Experimente zu teuer sind und nur Beobachtungsdaten verfügbar sind, wurde das „Double Machine Learning Framework“ entwickelt, um kausale Effekte zu extrahieren. Vor allem sind es technische Herausforderungen, um die gewünschten kausalen Effekte genau zu schätzen. Der zweite Grund, zusätzliche Informationen in der Analyse zu verwenden, besteht darin, ein quasi exper-

imentelles Setting zu schaffen. Was bedeutet das? In vielen Situationen stammen die Daten nicht aus einer randomisierten Kontrollstudie. Wenn zusätzliche Informationen verfügbar sind, auf die der Datenanalyst zurückgreifen kann, kann eventuell ein RCT nachgeahmt werden.

Das Problem an nicht-experimentellen Daten ist, dass sogenannte Confounder (Störvariablen) vorhanden sind, die die Ergebnisse verzerren. In obigem Beispiel war das die Variable „Rauchverhalten“, die sowohl das Tragen eines Feuerzeugs als auch das Entstehen von Krebs beeinflusst und dessen Nichtberücksichtigung die Ergebnisse verzerrt. Die Idee des „Double Machine Learning“-Ansatzes ist es nun, den Einfluss der Störvariablen sowohl auf das Ziel- als auch auf der Behandlungsvariablen mittels maschineller Lernverfahren durch Regression zu entfernen. Dadurch kann eine Situation erreicht werden, die dem eines randomisierten Experiments nahekommt („Quasi-Experimente“).

Eine weitere wichtige Richtung bei der Schätzung kausaler Behandlungseffekte ist die Berücksichtigung von Heterogenität. Die Idee ist, dass eine bestimmte Behandlung nicht alle Individuen mit der gleichen Quantität beeinflusst, sondern dass verschiedene Untergruppen unterschiedlich beeinflusst werden. Ein klassisches und bekanntes Beispiel ist, dass Männer und Frauen unterschiedlich auf die gleiche Dosis eines Arzneimittels reagieren. Das Konzept der personalisierten Medizin beruht auf der Heterogenität von Individuen und auf der Konstruktion von individualspezifischen medizinischen Behandlungsprogrammen. Ein Beispiel aus der Wirtschaft ist, dass Menschen unterschiedlich auf Marketingkampagnen reagieren und es daher effizient ist, spezifische Kampagnen zu entwerfen. In hochdimensionalen Settings, in denen wir viele Variablen für jedes Individuum/Objekt sammeln, ist es schwierig, die relevanten Untergruppen zu identifizieren und den zugehörigen Effekt zu schätzen. Der Grund dafür ist, dass es zu viele Untergruppen gibt. Für diese Aufgabe haben sich maschinelle Lernverfahren ebenfalls als sehr leistungsfähig erwiesen und bieten die Möglichkeit, effizientere, gruppenspezifische Strategien zu entwickeln.

Fazit: Maschinelle Lernmethoden sind sehr erfolgreich für die Vorhersage und setzen den neuen Standard in diesem Bereich. In letzter Zeit hat sich der Fokus auf kausale Fragen verlagert und Methoden des maschinellen Lernens für kausale Forschung werden gerade entwickelt. Darüber hinaus sind auch Vorhersage- und Kausalfragen aber auch eng miteinander verknüpft. Für echte intelligente oder autonome Systeme, die richtige Entscheidungen treffen, ist eine gute Vorhersage der nächsten Aktion erforderlich. Aber um dies in neuen „Umgebungen“ zu erreichen, ist ein kausales Verständnis von Mechanismen in komplexen Systemen erforderlich. Auf jeden Fall ist es ein sehr spannendes Feld für Forschung und – darauf aufbauend – können viele Anwendungen in Industrie und Wirtschaft in den nächsten Jahren und Jahrzehnten folgen.

Victor Chernozhukov (MIT - Massachusetts Institute of Technology), Martin Spindler (Universität Hamburg) und Ye Luo (Hong Kong University) sind Professoren für Statistik und Ökonometrie und beschäftigen sich in ihrer Forschung mit Methoden des Maschinellen Lernens / Künstlicher Intelligenz und kausaler Inferenz und dem Zusammenspiel von beiden Gebieten („Economic AI“).

Europlatz Frankfurt

Politik im Fokus der Märkte

Von Ulrich Kater

Einmal mehr sind die politischen Belastungsfaktoren das beherrschende Thema an den Finanzmärkten. Der Handelsstreit zwischen den Vereinigten Staaten und China wird wahrscheinlich in den kommenden Monaten dem gleichen Hü und Hott gehorchen wie bisher, und ab August wird sich eine neue britische Regierung mit dem alten Problem des Brexits beschäftigen, wahrscheinlich mit härterer Gangart. Im Herbst können dann noch Turbulenzen um die italienische Staatsschuld hinzukommen, wenn der Konfrontationskurs der Regierung in Rom zu einer Abwertung der Landesbonität durch die Ratingagenturen führen sollte. Geostrategen stellen all diese Entwicklungen gerne in einen größeren Zusammenhang. Demnach ist nichts weiter als die Auflösung der von Amerika dominierten Nachkriegsordnung unterwegs. Diese Umwälzung senkt das Ausmaß an internationaler Kooperation und erhöht die Gefahr von Großereignissen wie dem Brexit bis hin zu vollkommen neuen Bedrohungen wie der Möglichkeit von Cyberattacken, welche ganze Volkswirtschaften flächendeckend lahmlegen könnten.

Auf den ersten Blick passen die gegenwärtigen Konjunkturmeldungen hierzu in das trübe Bild. Desaströse Produktionszahlen in der deutschen Industrie, abbröckelnde Auftragsbestände und nicht zuletzt ein Geldmarkt, der weitere Zinssenkungen fest einplant, im Euroraum wie in den Vereinigten Staaten. Hat Donald Trump die Weltwirtschaft kleingekriegt? Natürlich ist das etwas dran. Insbesondere außenwirtschaftlich orientierte Volkswirtschaften leiden.

Deutschland hatte als eine der offensten Ökonomien der Welt daher im vergangenen Jahr den stärksten Konjunkturrückgang; Teile der Industrie sind alarmiert über die aktuellen Schwächesignale. Machen wir uns nichts vor: Selbst wenn die Rezession vermieden werden kann, fällt das Wachstum in diesem und im kommenden Jahr deutlich ab.

Beim näheren Hinschauen ist das Bild diffuser. Der Handelskrieg bleibt auf Feindseligkeiten zwischen den großen Handelsblöcken in Nordamerika, in der EU oder in China beschränkt. Diese weisen Exportquoten von lediglich 9, 13 und 20 Prozent auf, eigentlich zu wenig, um diese großen Konjunkturanker durch Zölle kernen zu lassen. Konjunkturell also vielleicht gerade noch verkraftbar, sind die Veränderungen der Rahmenbedingungen für einzelne Unternehmen unter Umständen verhängnisvoll. Produktionsstandorte und Absatzländer sowie der Technologiegehalt der Produkte rücken in den Fokus. Hier zeigen die global tätigen Unternehmen bereits eine rege Ausweichaktivität. Produktionsketten werden neu organisiert, einschließlich Rückverlagerungen und Neuinvestitionen. Trotzdem wird nicht zu verhindern sein, dass sämtliche Geschäftsmodelle neu bewertet werden, was an den Aktienmärkten noch zu Überraschungen führen könnte – eher mehr negative als positive. Verlieren werden in jedem Fall die Verbraucher weltweit, weil die auf materielle Vorteile angelegte Globalisierung der vergangenen Jahrzehnte nun aus politischen Gründen langsam zurückgedreht wird. Der Autor ist Chefvolkswirt der Deka-Bank.



WIRTSCHAFTSBÜCHER

Mehr als Blech

Ein Porträt des Werkzeugbauers Trumpf

Als „Hidden Champion“ charakterisiert der Mannheimer Wirtschaftshistoriker Jochen Streb den Werkzeugbauer Trumpf am Beginn seines Firmenporträts. Die Kombination aus geringem Bekanntheitsgrad und großem wirtschaftlichen Erfolg mache den Spitzenreiter der Branche aus Ditzingen bei Stuttgart mit zuletzt 3,6 Milliarden Euro Umsatz zum Musterbeispiel eines heimlichen Weltmarktführers. Beindruckend seien vor allem die Langlebigkeit und das fortgesetzte wirtschaftliche Wachstum des inhabergeführten, bald 100 Jahre alten Familienunternehmens. Allein in den letzten 60 Jahren habe sich der Umsatz dort um durchschnittlich 12 Prozent jährlich erhöht, und die Zahl der Mitarbeiter im Inland und Ausland sei von 300 auf 13 500 gestiegen.

Tatsächlich gehört die auf hochwertige Stanz- und Lasermaschinen spezialisierte Trumpf-Gruppe mit mehr als 70 Tochtergesellschaften heute zu den größten Anbietern der Branche. Begonnen hat der Weg zum Weltunternehmen bescheiden: Die 1923 als Julius Geiger GmbH in Stuttgart von den Mechanikern Alfred Kern und Eduard Klein zusammen mit dem Kaufmann Christian Trumpf gegründete mechanische Werkstatt stellte zunächst nur mit wenigen Mitarbeitern biegsame Wellen für Maschinen zur Metallbearbeitung her. Nach 1930 ergänzte eine neuartige Elektrohohlblechschere das Angebot, mit der sich die Firma unter ihrem Geschäftsführer Christian Trumpf „zum Lieferanten der nationalsozialistischen Rüstungsindustrie mit 150 Beschäftigten entwickelte“, heißt es.

Den Aufstieg zum Weltmarktführer von Blechschneidemaschinen datiert Streb in seinem Buch allerdings erst, seit Berthold Leibinger 1961 Leiter der Konstruktionsabteilung des inzwischen Trumpf GmbH & Co KG benannten Unternehmens wurde und von 1969 bis 2005 Vorsitzender der Geschäftsführung war. Dessen als Student konzipierte, später weiterentwickelte „Kopierblechmaschine“, vor allem aber die Markteinführung eines hauseigenen Lasers in den achtziger Jahren seien entscheidende technologische Sprünge für das Unternehmen gewesen. Parallel dazu habe Leibinger mit der Gründung von ausländischen Produktionsstätten sowie Wartungs- und Vertriebsgesellschaften auf drei Kontinenten die Internationalisierung vorangetrieben. Nach der auch für Trumpf existenzbedrohenden Maschinenbaukrise Anfang der neunziger Jahre hätten organisatorische Neuerungen wie die Fließfertigung das Unternehmen nachhaltig gestärkt. Seit dem Generationswechsel 2005 zu Leibingers Tochter Nicola Leibinger-Kammüller bemühe sich der Maschinenbauer besonders um den chinesischen Markt. Er versuche zudem, mit Finanz-Service sowie als Software-Entwickler und Dienstleister der Industrie 4.0 Fuß zu fassen.

Die Geschichte von Trumpf erzählt Streb mit vielen Details, dabei sachbezogen und ohne Hang zur Hagiographie. So wird die Frühphase von der großen Inflation in der Weimarer Republik, der nationalsozialistischen Rüstungspolitik und der Besatzungszeit bestimmt. Kapitel 3 beschreibt den Innovationschub für die Blechbearbeitung in der Wirt-

schaftswunderzeit, Kapitel 4 den Quantensprung zum Laser und andere Diversifizierungsversuche im Jahrzehnt bis zur Wiedervereinigung, Kapitel 5 die europäische und nordamerikanische Expansion sowie den Wettlauf um Asien. Die Kapitel 6 bis 9 widmen sich internen Fragen wie der Unternehmenskommunikation, betrieblicher Sozialpolitik, der Flexibilisierung von Arbeitszeiten und organisatorischen Veränderungen zur Erhöhung der Arbeitsproduktivität.

Da Trumpf über kein gutausgestattetes Archiv verfügt und für die ersten fünfzig Jahre Primärquellen fehlten, erläutert Streb alternativ besser dokumentierte, vergleichbare Vorgänge aus anderen Unternehmen und bettet das Ganze in volkswirtschaftliche Zusammenhänge ein. Letztlich interessiert Streb die Frage, welche Managementleistungen Trumpf das langfristige Überleben beschert haben. Im Rückblick steht für den Wirtschaftshistoriker außer Zweifel, dass „der wirtschaftliche Erfolg der Internationalisierung (Vergrößerung des geographischen Absatzgebietes für etablierte Produkte) und der Innovation (Schaffung von Nachfrage für bisher unbekannte Produkte) zu verdanken ist“.

Der ungebremste Mut zur Veränderung habe sicherlich auch mit der engen Verschmelzung von Familie und Unternehmen zu tun, meint Streb: „Den wirtschaftlichen Erfolg von Trumpf zu mehreren, stellt ein übergeordnetes Ziel von bisher zwei Generationen der Familie Leibinger dar.“ Dem dynastisch denkenden Clan mit seinem engen Zusammenhalt und den in einem eigenen Familienkodex festgeschriebenen eisernen Regeln werde das mit etwas Glück vermutlich auch künftig gelingen: „Angesichts der Bereitschaft der aktuell verantwortlichen Generation Leibinger, sich mit ganzer Kraft dem eigenen Unternehmen zu widmen, der Solidität der finanziellen Strukturen, der Präsenz in allen wichtigen Volkswirtschaften von Amerika bis China und eines ganzen Bündels ambitionierter Innovationsprojekte scheint das Unternehmen gut für das nächste Jahrzehnt gerüstet.“

Unbemerkt von der Öffentlichkeit agiert Trumpf nicht mehr. Schon die überraschende Entscheidung des im vergangenen Oktober verstorbenen Unternehmenslenkers Berthold Leibinger, die Geschäftsführung an seine Tochter Nicola Leibinger-Kammüller zu übertragen, sorgte seinerzeit für viel Aufmerksamkeit. Die neue Chefin, damals 46 Jahre alt, entsprach als Frau, Mutter von vier Kindern und promovierte Germanistin in keiner Weise dem traditionellen Anforderungsprofil der konservativen Maschinenbaubranche. Doch in dem guten Dutzend Jahren seither erhöhten sich Umsatz und Mitarbeiterzahl auf mehr als das Doppelte, und das Unternehmen kam zuletzt auf einen Jahresgewinn von 514 Millionen Euro. Das wachsende Interesse der Medien an der ebenso erfolgreichen wie sympathischen, pietistisch geprägten Firmenchefin sorgte dafür, dass der vormals heimliche Weltmarktführer auch außerhalb der Fachkreise als deutsches Vorzeige-Unternehmen wahrgenommen wird. ULLA FÖLSING

Jochen Streb: **Trumpf. Geschichte eines Familienunternehmens.** Hanser Verlag, München 2019. 544 Seiten, 34 Euro

Vor der KI kommt die digitale Automatisierung

„Technologie befreit den Menschen vor fehleranfälligen Tätigkeiten“

Die Begriffe überstürzen sich und gehen häufig durcheinander: Digitalisierung, Künstliche Intelligenz und Big Data. Verwirrung herrscht auch über die Implementierung digitaler Techniken in Unternehmen. „Digitalisierung oder Künstliche Intelligenz sind keine Techniken, die man in speziellen Projekten umsetzt“, ist Tom Becker überzeugt. Becker leitet die Tätigkeiten des amerikanischen Data-Analytics-Softwareherstellers Alteryx in Deutschland, Österreich und der Schweiz. Digitalisierung und Künstliche Intelligenz müssen das gesamten Unternehmen durchdringen und möglichst viele Mitarbeiter erreichen und einbinden.

Junge Unternehmen fangen gleich digitalisiert an, beobachtet Becker. Großunternehmen haben sich sehr weit digitalisiert. Der Mittelstand stehe noch

weitgehend am Anfang. Von Künstlicher Intelligenz sei man noch weit entfernt. Auch wenn jemand für die langfristige, strategische Planung digitale Simulationsmodelle verwendet, wendet der noch keine Künstliche Intelligenz an. „Daten sammeln, Daten strukturieren, Entwicklungen simulieren und daraus Schlüsse ziehen, ist ganz klassische Datenverarbeitung“, sagt Becker. Aber auf dieser Stufe können Unternehmen noch große Effizienzsteigerungen erzielen, ist er überzeugt.

„Die Digitalisierung der Abläufe schafft Freiräume für andere, komplexere Tätigkeiten“, sagt Becker. Dieser Effekt werde häufig unterschätzt. Nur in den seltensten Fällen führt Digitalisierung zur Freisetzung von Mitarbeitern. Für das Unternehmen habe die Digitalisierung zu-

dem den Vorteil, dass fehleranfällige Routinetätigkeiten vom Computer fehlerfrei erledigt werden, weil er nicht ermüdet.

Erst wenn sich das System auch das richtige Auswertungsmodell selbst sucht und es aufgrund aktueller Daten verbessert, könne man von Künstlicher Intelligenz und speziell von Machine Learning sprechen. Um das industriell einsetzen zu können, bedarf es aber erst einmal der Erfassung großer Datenmengen. „Ohne genügend Daten bleibt Künstliche Intelligenz nahe am Zufall“, sagt Becker. Künstliche Intelligenz erfordere auch keine speziellen Kenntnisse statistischer Programmiersprachen. Es gebe entsprechende Software am Markt, die man kaufen und einsetzen kann. Das Argument, man habe zu wenig IT-Kapazität im Unternehmen, lasse er daher nicht gelten. geg.