

Luo, Ye; Spindler, Martin; Bach, Philipp

Article

Dynamic Pricing mit Künstlicher Intelligenz - Fallstudie aus dem Ride-Sharing-Markt

Marketing Review St.Gallen

Provided in Cooperation with:

Universität St. Gallen, Institut für Marketing und Customer Insight

Suggested Citation: Luo, Ye; Spindler, Martin; Bach, Philipp (2019) : Dynamic Pricing mit Künstlicher Intelligenz - Fallstudie aus dem Ride-Sharing-Markt, Marketing Review St.Gallen, ISSN 1865-7516, Thexis Verlag, St.Gallen, Vol. 36, Iss. 5, pp. 48-54

This Version is available at:

<https://hdl.handle.net/10419/276057>

Standard-Nutzungsbedingungen:

Die Dokumente auf EconStor dürfen zu eigenen wissenschaftlichen Zwecken und zum Privatgebrauch gespeichert und kopiert werden.

Sie dürfen die Dokumente nicht für öffentliche oder kommerzielle Zwecke vervielfältigen, öffentlich ausstellen, öffentlich zugänglich machen, vertreiben oder anderweitig nutzen.

Sofern die Verfasser die Dokumente unter Open-Content-Lizenzen (insbesondere CC-Lizenzen) zur Verfügung gestellt haben sollten, gelten abweichend von diesen Nutzungsbedingungen die in der dort genannten Lizenz gewährten Nutzungsrechte.

Terms of use:

Documents in EconStor may be saved and copied for your personal and scholarly purposes.

You are not to copy documents for public or commercial purposes, to exhibit the documents publicly, to make them publicly available on the internet, or to distribute or otherwise use the documents in public.

If the documents have been made available under an Open Content Licence (especially Creative Commons Licences), you may exercise further usage rights as specified in the indicated licence.

Marketing Review St. Gallen



5 | 2019 **SCHWERPUNKT** Das Geschäft mit der Transparenz • Dynamic Pricing – Influence on Consumers • Dynamisches Pricing in der Kundenwahrnehmung • Akzeptanz von Dynamischen Preisen – Fallstudie • Umsetzung von Dynamic Pricing • Applicability of Pay-What-You-Want Strategies **GASTBEITRAG** Die Philosophie des Preises **KOMMENTAR** Marketing Intelligence – oder gibt es noch etwas anderes? **SPEKTRUM** Trends in der Customer-Journey • Lead-Generierung • Conversational Agents aus der Kundenperspektive

www.marketing-review.ch



Rethinking Pricing

Dynamic Pricing mit Künstlicher Intelligenz

Fallstudie aus dem Ride-Sharing-Markt

Big Data stellt Unternehmen vor die Herausforderung, Daten zur Weiterentwicklung des Geschäftsmodells zu verwenden und dabei auf modernste ökonomische und statistische Methoden zu setzen. Damit Unternehmensentscheidungen langfristig zum Geschäftserfolg beitragen, kommt der Kausalität eine herausragende Rolle zu.

Ye Luo, Prof. Dr. Martin Spindler, Philipp Bach

Einführung

Die im Zuge der Digitalisierung steigende Verfügbarkeit von Daten eröffnet Unternehmen einerseits neue Möglichkeiten zur Weiterentwicklung und Optimierung ihres Geschäftsmodells. Andererseits werden die Unternehmen vor die Herausforderung gestellt, diese neue Datengrundlage bei der Abbildung relevanter Prozesse zielführend auszuwerten. Dabei kommt modernen ökonomischen und statistischen Methoden eine besondere Bedeutung zu. Insbesondere besteht die Herausforderung darin, den kausalen Charakter zentraler Fragestellungen zu erkennen und im Zuge der datengetriebenen Modellierung zu berücksichtigen.

In den letzten Jahren hat eine neue Generation von Unternehmen, deren Strategie auf der Nutzung digitaler Dienste wie bspw. Apps beruht, die Geschäftswelt revolutioniert. Zu den bekanntesten Beispielen gehören Amazon, Google, Uber, Tesla, Netflix und AirBnB. Im Kern der neuen digitalen Geschäftsmodelle steht allerdings nicht lediglich die Sammlung grosser Datenmengen in aussergewöhnlich hoher Qualität und Quantität. Der Erfolg von *Big Tech*¹ beruht insbesondere auf der intelligenten Auswertung dieser Datengrundlage bei der stetigen Weiterentwicklung des Geschäftsmodells, wie zum Beispiel bei der Optimierung der angebotenen Services oder von Abschlussprozessen. Die rasante Entwicklung leistungsstarker statistischer Methoden aus den Bereichen Machine Learning und Künstlicher Intelligenz, vor allem Deep Learning, sowie die nahezu unbegrenzte Verfügbarkeit von Rechenkapazitäten schaffen neue Möglichkeiten, datengetriebene Verfahren zur Beantwortung wichtiger Fragestellungen in grundsätzlich allen Unternehmensbereichen einzusetzen. Begriffe wie Digitalisierung, Big Data und Künstliche Intelligenz deuten auf einen Paradigmenwechsel in der Unternehmensführung hin: Unter-

nehmensentscheidungen werden in Zukunft hypothesengetrieben und evidenzbasiert sein. Die Kompetenz, kausale Fragestellungen zu erkennen und diese mit sogenannten strukturierten Modellen zu beantworten, ist für Unternehmensentscheidungen von grösster Bedeutung und letztendlich für den langfristigen Geschäftserfolg existenziell. Der Umfang der ökonomisch-statistischen (kurz „ökonometrischen“) Modellierung übersteigt hier bei Weitem die momentane Praxis der Prediction-Analytics.

Die im Folgenden beschriebene Fallstudie zeigt, wie ein Unternehmen für Online-Vermittlung von Fahrdiensten und Taxis (Ride-Sharing) moderne statistische Verfahren aus dem Bereich des sogenannten „Deep Learning“ einsetzt, um eine optimale dynamische Preissetzung (Dynamic Pricing) zu erreichen. Das entwickelte Preismodell ist das Resultat einer intensiven Kooperation von internationalen Wissenschaftlern der Universität Hamburg, der University of Hongkong und des Data-Science-Kompetenzzentrum des Unternehmens im Rahmen eines Projektes mit Economic AI.

Aufgrund seiner seit jeher hohen Relevanz steht das Forschungsgebiet Dynamic Pricing an der Schnittstelle zahlreicher Literaturstränge. In den vergangenen Jahren wurden zahlreiche Literaturübersichten über dieses komplexe Themengebiet veröffentlicht, sodass wir an dieser Stelle auf die aktuelle Literaturübersicht von den Boer (2015) und die darin aufgeführten Quellen verweisen. Dynamic Pricing kann als Kombination von Statistischem Lernen (Statistical Learning) und Preisoptimierung (Price-Optimization) aufgefasst werden (vgl. den Boer, 2015), wobei in der Fachliteratur unterschiedliche Definitionen verwendet werden. Allgemein kann Dynamic Pricing daher als eine Preispolitik verstanden werden, die zur Erzielung eines möglichst grossen Erlöses eingesetzt wird.

Ye Luo

Professor für Statistik und Ökonometrie an der University of Hongkong

Economic AI
(www.economicai.com)
kurtluo@hku.hk

Prof. Dr. Martin Spindler

Professor für Statistik an der Universität Hamburg

Economic AI
Tel.: +49 (0) 40 42838-1544
martin.spindler@uni-hamburg.de
<https://www.bwl.uni-hamburg.de/statistik/wissenstransfer.html>

Philipp Bach

Wissenschaftlicher Mitarbeiter am Lehrstuhl für Statistik an der Universität Hamburg

Tel.: +49 (0) 40 42838-1538
philipp.bach@uni-hamburg.de

Vor allem der Nachfrageschätzung kommt im Zuge der dynamischen Preismodellierung eine herausragende Bedeutung zu. Der Preis wird hier als Steuerungsvariable vom Unternehmen gesetzt. Dieser richtet sich nach der Zahlungsbereitschaft der Kunden und variiert dementsprechend von Kunde zu Kunde. Der Mehrwert, den ein Unternehmen mit dem Einsatz dynamischer Preise erzielt, hängt hauptsächlich von zwei Faktoren ab: Erstens, eine geeignete ökonomische Modellierung, bei der der inhärent kausale Charakter der Nachfrageschätzung adressiert wird, und, zweitens, eine möglichst präzise statistische Schätzung. Letztere profitiert sowohl von einer hohen Datenqualität und -quantität (Big Data) als auch von exakten statistischen Verfahren, wie zum Beispiel Deep Learning, welches im Zuge der Fallstudie Anwendung fand.

Zusammenfassend lässt sich festhalten: Die Sammlung grosser Datenmengen („Big Data“) schafft an sich noch keinen Mehrwert. Nur durch eine zielgerichtete datenbasierte Analyse, der eine sorgfältige ökonomische Modellierung zu Grunde liegt, können konkrete Handlungsempfehlungen abgeleitet werden. Erst dann können kausale Schlussfolgerungen gezogen und somit Unternehmensentscheidungen getroffen werden, die einen Mehrwert schaffen.

Der Einsatz statistischer Methoden im Rahmen datenbasierter Unternehmensentscheidungen

Im Rahmen datengetriebener Unternehmensentscheidungen können statistische Verfahren zum Erreichen von zwei verschiedenen Zielen eingesetzt werden:

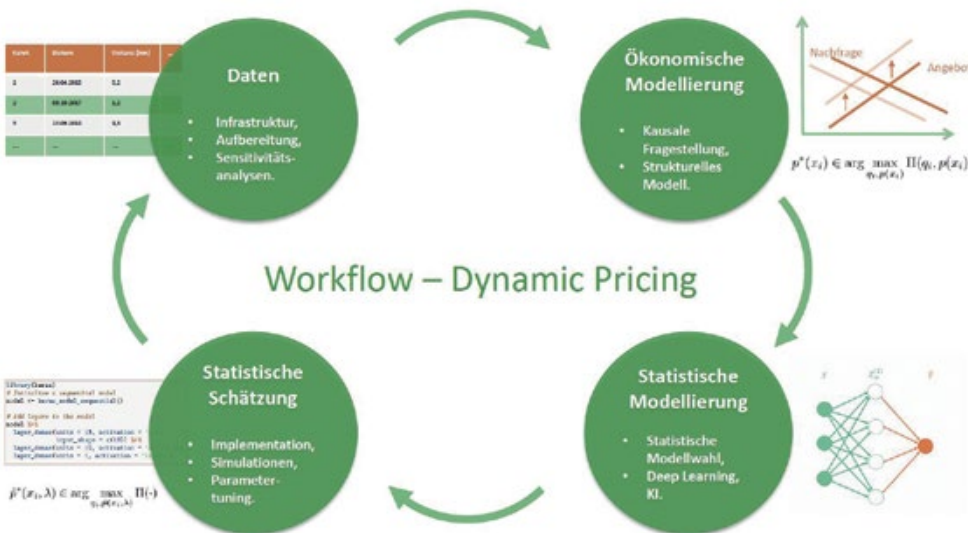
für Vorhersagen (Prediction) oder zur Schätzung sogenannter kausaler Effekte (kausale Inferenz).² Bei der Vorhersage sollen beobachtete Daten dazu verwendet werden, eine Zielvariable möglichst exakt vorauszusagen. Statistische Methoden aus den Bereichen Maschinelles Lernen und Künstliche Intelligenz (Deep Learning) wurden in der Vergangenheit in vielen Anwendungsbereichen sehr erfolgreich für Vorhersagezwecke eingesetzt. Eine beispielhafte Anwendung ist die Studie von Bajari, Nekipelov, Ryan & Yang (2015), in der die Absatzmenge verschiedener Produkte in Supermärkten mithilfe (kombinierter) ML-Methoden vorausgesagt wird.

Das Ziel kausaler Inferenz hingegen liegt in der Messung des Einflusses einer erklärenden Variable X auf eine Zielgrösse Y. Eine beispielhafte kausale Fragestellung wäre „Wie wirkt sich die Marketingmassnahme X auf die Absatzzahlen Y aus?“ Soweit eine Randomisierung im Rahmen eines experimentellen Setups möglich ist, kann der kausale Effekt durch A/B-Testings ermittelt werden. A/B-Tests wurden in der Vergangenheit im grossen Stil, u.a. zur optimalen Gestaltung von Websites, Apps und Preismodellen durchgeführt. Die Randomisierung führt dazu, dass die Varianten A und B den App-Nutzern oder Website-Besuchern zufällig und daher unabhängig von deren Charakteristika (Zahlungsbereitschaft, Bonität, vorherige Suchhistorie etc.) angezeigt werden. Sogenannte Scheinkorrelationen, d.h. gemessene, nicht-kausale Abhängigkeiten zwischen Variablen, können somit ausgeschlossen werden.

In der Praxis hingegen sind A/B-Tests und Experimente nicht immer durchführbar, beispielsweise aufgrund hoher Kosten und Risiken. Viele für den Geschäftserfolg entscheidende Fragestellungen können dann lediglich auf der Basis von beobachte-

Abb. 1: Iterativer Workflow beim Einsatz statistischer Methoden für Unternehmensentscheidungen

Hier am Beispiel der Fallstudie zum Dynamic Pricing im Ride-Sharing

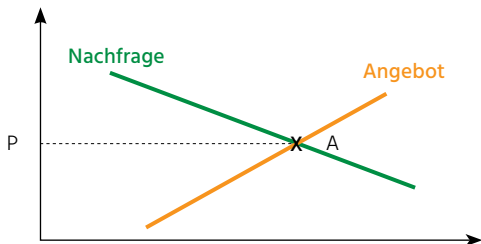


Quelle: Economic AI.

Abb. 2: Beispiel einer kausalen Fragestellung

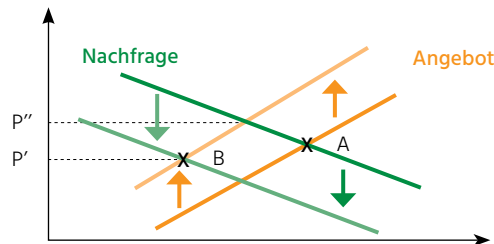
Ein Unternehmen verändert sein Angebot und möchte die Reaktion der Nachfrage beurteilen. Gleichzeitig stattfindende Nachfrageänderungen erschweren die Beantwortung dieser kausalen Fragestellung: Der realisierte Preis P' weicht von dem ohne Nachfrageänderung zu erwartenden Preis P'' ab.

Ausgangssituation



In der Ausgangssituation schneiden sich die Angebot- und Nachfragekurve im Punkt A. Es ergibt sich der Gleichgewichtspreis P .

Gleichzeitige Angebots- und Nachfrageänderung



Bei gleichzeitiger Änderung der Nachfrage- und Angebotskurven ändern sich Gleichgewichtsmenge und Gleichgewichtspreis ($P \rightarrow P'$). Das Unternehmen kann die Nachfrageänderung aufgrund des geänderten Angebots nicht identifizieren.

Quelle: Economic AI.

ten Daten (Observational Data) beantwortet werden. Das Kernproblem derartiger kausaler Studien liegt in der Endogenität: Es besteht möglicherweise eine nicht-beobachtbare Abhängigkeit zwischen Faktoren, die neben der erklärenden Variable (X) einen Einfluss auf die Zielvariable (Y) besitzen. Schätzt man die Preiselastizität der Nachfrage auf Basis beobachteter Daten, ist der Effekt des Preises

endogen: Der Preis bestimmt nicht nur die Nachfrage, sondern auch das Angebot – es bestehen Rückkopplungseffekte. Darüber hinaus gibt es häufig unbeobachtete Faktoren (wie beispielsweise Qualitätswahrnehmung), die einen Einfluss auf die Nachfrage und den Preis haben und somit den Preiseffekt verzerren können.

Die Beantwortung kausaler Fragestellungen ist im Allgemeinen schwie-

riger als reine Vorhersagen, da ein gründliches Verständnis der Zusammenhänge von entscheidender Bedeutung ist. Es ist selbst dann noch möglich genaue Vorhersagen zu erstellen, wenn der Zusammenhang zwischen zwei Variablen vollständig auf einer Scheinkorrelation beruht. Werden in einer solchen Situation hingegen kausale Schlüsse gezogen, würde dies zu fatalen Unternehmensentscheidungen führen. Viele relevante Problemstellungen sind letztlich kausaler Natur. Methoden der Prediction-Analytics oder Business-Analytics können nicht zu deren Beantwortung herangezogen werden, da diese regelmässig zu falschen Entscheidungen führen.

Zusammenfassung

Durch die Digitalisierung stehen Unternehmen immer grössere Datensätze zur Verfügung. Optimale Geschäftsentscheidungen können allerdings nur getroffen werden, wenn aus den Daten die richtigen Schlüsse gezogen werden. Um sich einen dauerhaften Wettbewerbsvorteil zu sichern, ist es notwendig, ökonomische Modelle und maschinelle Lernverfahren zielführend zu kombinieren – „Economic AI“. Anhand eines Beispiels aus dem Ride-Sharing-Markt wird gezeigt, wie Künstliche Intelligenz für Preisoptimierung (Dynamic Pricing) eingesetzt werden kann.

Fallstudie: Dynamic Pricing am Beispiel eines führenden Ride-Sharing-Anbieters

Das Unternehmen der Fallstudie setzte ursprünglich ein lineares Preissystem

für die Vermittlung von Fahrdiensten (Ride-Sharing) ein, bei dem der Preis linear von der zurückgelegten Strecke und zwei weiteren Faktoren abhing. Im Rahmen des Projektes sollte ein nicht-lineares, dynamisches Preissystem entwickelt werden, das eine Vielzahl von Variablen in die Preisermittlung miteinbezieht.

Die zur Entwicklung des optimalen Preismodells notwendigen Arbeitsschritte lassen sich anhand des Workflows in Abbildung 1 gliedern.

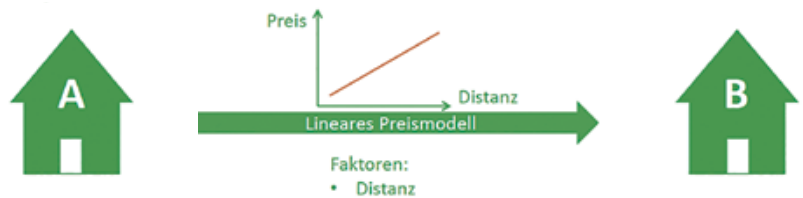
Daten

Das Geschäftsmodell des Ride-Sharing-Anbieters ist vollständig App-basiert, d.h. zum Zeitpunkt der Modellierung lagen alle Daten über getätigte Fahrten bereits in hoher Qualität vor. Die Datengrundlage, auf welche zurückgegriffen werden konnte, umfasste daher nicht nur eine grosse Anzahl an Beobachtungen (> 10 Mio. Fahrten), sondern auch eine Vielzahl an Variablen, u.a. zu Fahrtbeginn (Datum und Uhrzeit), Fahrtdauer, Start- und Endpunkt der Fahrt, Stadt, zurückgelegte Strecke und gezahlter Preis. Im Rahmen einer Vorstudie wurden diese Daten zunächst bereinigt und aufbereitet, um dann mit externen Daten, wie beispielsweise Temperatur-, Smog- und Verkehrsdaten (z.B. Staus) kombiniert zu werden. Über die Qualität und Quantität hinausgehend, weist die in der Fallstudie verfügbare Datengrundlage ein typisches Unterscheidungsmerkmal digitaler gegenüber traditioneller (physischer) Geschäftsmodelle auf: Die Ride-Sharing-App ermöglicht es, sowohl Informationen über tatsächlich durchgeführte Fahrten als auch über in der App getätigte Anfragen, die nicht zu einer Buchung führten, zu sammeln – sogenannte „Bubbling“-Daten.

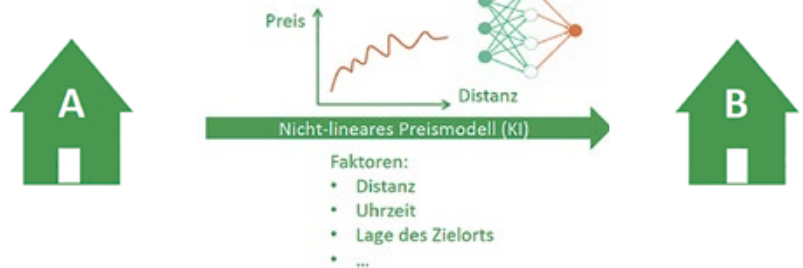
Abb. 3: Veranschaulichung des neuen nicht-linearen Preismodells (unten) gegenüber dem vorherigen linearen Modell (oben)

Im neuen Modell werden zahlreiche Faktoren berücksichtigt. Die Modellierung ist flexibler als im ursprünglichen Pricing Modell.

Ursprüngliches, lineares Preismodell



Neues, nicht-lineares Preismodell



Quelle: Economic AI.

Ökonomische Modellierung

Bei der Entwicklung eines optimalen Preismodells gilt es, verschiedene Effekte im Hinblick auf die Auslastung der zur Verfügung stehenden Kapazitäten und der Erlösmaximierung gegeneinander abzuwägen: Zwar führen höhere Fahrpreise zu höheren Erlösen je Fahrt. Allerdings nimmt gleichzeitig die Anzahl gebuchter Fahrten ab. Umgekehrt könnten mit niedrigeren Preisen neue Kundensegmente angesprochen werden, wodurch eine höhere Auslastung erzielt werden könnte. Um das richtige Verhältnis dieser Effekte zu ermitteln, muss die Nachfragefunktion, genauer gesagt die Preiselastizität der Nachfrage, geschätzt werden. Die

Schätzung der Nachfragefunktion ist der Kern für die Implementierung von Dynamic-Pricing-Systemen, wobei der Schätzgenauigkeit eine besonders grosse Bedeutung zukommt.

Die Schätzung der Nachfragefunktion stellt, wie bereits im vorherigen Kapitel geschildert, eine inhärent kausale Fragestellung dar. Bei der Lösung kann grundsätzlich entweder auf randomisierte Experimente oder strukturelle Modellierung zurückgegriffen werden. Momentan finden randomisierte Experimente grosse Anwendung bei Tech- und Internetunternehmen, da digitalisierte Prozesse dafür geradezu ideal sind. Im Zuge des Projektes war dies nicht möglich, sodass gesammelte Daten aus der Vergangenheit verwendet

wurden. Das kausale Grundproblem in der Fallstudie ist nun folgendes: Es liegen nur Daten vor, die unter dem „alten“ Preismodell erhoben wurden. Die Fragestellung hingegen zielt darauf ab, wie sich Konsumenten unter einem neuen Preismodell verhalten würden (sog. Counterfactual), d.h. für welches noch keinerlei Transaktionen vorliegen. Um dies beantworten zu können, müssen weitere Annahmen getroffen werden und ein sogenanntes strukturelles Modell entwickelt werden. Strukturelle Modelle haben eine lange Tradition in der Ökonometrie und dienen dazu „strukturelle“ Parameter zu schätzen, hier den Einfluss von Preis auf die Nachfrage in Abhängigkeit von anderen Variablen wie Wetter, Tageszeit, etc. Zur Schätzung der Preiselastizität der Nachfrage wurde zunächst ein ökonomisches Modell der Entscheidung eines Kunden, ein sogenanntes Consumer-Choice-Model, aufgestellt: Ein Konsument entscheidet sich für die Buchung der Fahrt, wenn der in der Ride-Sharing-App angezeigte Fahrpreis unter seiner maximalen Zahlungsbereitschaft liegt. Letztere wird in Abhängigkeit von zahlreichen Faktoren modelliert, u.a. der Lage von Abfahrts- und Zielort und der Tageszeit.

Statistische Modellierung

Die Schätzung der maximalen Zahlungsbereitschaft profitiert von der Qualität und Quantität der vorliegenden Transaktionsdaten. Erstens waren Informationen zu Buchungsanfragen verfügbar, bei denen der angezeigte Preis über dem Reservationspreis des Nutzers lag, also der Nutzer trotz der Anfrage kein Taxi bestellt hat. Diese Bubbling-Daten sind höchst aufschlussreich, um die maximale Zahlungsbereitschaft zu ermitteln. Zweitens wurden eine Vielzahl interner und externer Daten, bspw. Wet-

Kernthesen

1. Intelligente Datennutzung wird in Zukunft zum entscheidenden Wettbewerbsvorteil für Unternehmen.
2. Erfolgreiche Unternehmen von morgen benötigen die Kompetenz, kausale Fragestellungen zu erkennen.
3. Eine Kombination von Künstlicher Intelligenz und ökonomischer Modellierung ist für kausale Problemstellungen wie Dynamic Pricing und Financial Planning erforderlich.
4. Ansätze, die nur auf Korrelationen statt Kausalität beruhen, führen zu falschen Geschäftsentscheidungen.
5. Zielführende modellbasierte Lösungsansätze berücksichtigen die spezifischen Gegebenheiten des Unternehmens und des Marktes.
6. Die Fallstudie zeigt, wie durch smarte Datennutzung und Modellierung Gewinne und Erlöse gesteigert werden.

terdaten, verwendet, um die Zahlungsbereitschaft zu modellieren – insgesamt über 350 Variablen. Drittens ermöglichte eine hohe Anzahl an Beobachtungseinheiten eine genaue Schätzung mithilfe moderner Methoden aus dem Bereich des Deep Learning, die selbst bei hochkomplexen Zusammenhängen präzise Ergebnisse liefern. Als statistische Methoden wurden tiefe neuronale Netze ausgewählt, da ihre Performance insbesondere bei grossen Datensätzen die anderer Machine-Learning-Algorithmen übersteigt, wie schematisch in Abbildung 4 dargestellt. Grundsätzlich treten bei diesen statistischen Verfahren zwar unter statistischen Gesichtspunkten „technische“ Probleme auf, wie z.B. systematisch verzerrte und nicht normalverteilte Schätzer, in den letzten Jahren wurden jedoch Methoden entwickelt, um diese zu lösen.

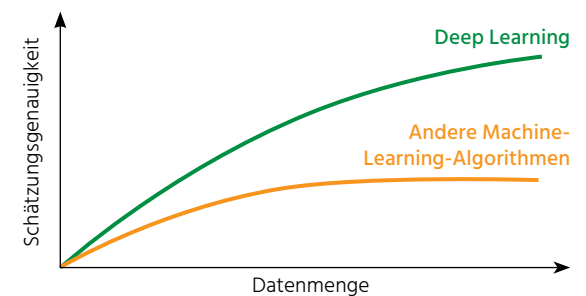
Statistische Schätzung

Im Zuge der Analyse wurden zahlreiche Simulation- und Plausibilitätsprüfungen durchgeführt, um mögliche

kontraproduktive Effekte einzugrenzen und letztendlich auszuschliessen. Eine Herausforderung bei der Ermittlung des optimalen Preismodells lag beispielsweise in möglichem strategischem Verhalten der Nutzer: Liegt der Fahrpreis, der in der App angezeigt wird, über der eigenen Zahlungsbereitschaft, könnte ein Nutzer abwarten und die Buchung zu einem späteren Zeit-

Abb. 4: Veranschaulichung des Performancevorteils

Deep Learning gegenüber anderen ML-Methoden bei grossen Datensätzen



Quelle: Economic AI.

Handlungsempfehlungen

Viele betriebliche Probleme lassen sich nicht mit Business-Analytics (Aufdecken von Korrelationen) lösen, sondern erfordern die Kombination von KI und ökonomischer Modellierung – kurz „Economic AI“. Entscheidungsträger müssen künftig kausale Fragestellungen erkennen, um zielführende Handlungsempfehlungen abzuleiten. Eine Vielzahl unternehmerischer Problemstellungen ist kausaler Art, so z.B. Dynamic Pricing, Financial Planning und die Planung von Marketingmassnahmen.

Die Kombination von ökonomischer Theorie und statistischer Performance wird künftig zum entscheidenden Erfolgsfaktor.

punkt, wenn der Preis niedriger ist, vornehmen. Im Zuge aufwendiger Simulationen wurden verschiedene Preismodelle miteinander verglichen, um letztendlich empirisch die optimale Preissetzungsregel zu bestimmen.

Ergebnis

Das Endergebnis des Projekts war ein nicht-lineares Preissystem, bei dem eine Vielzahl von Faktoren, die datengetrieben ausgewählt wurden, den Preis bestimmt. Dadurch konnten Erlössteigerungen aus den vermittelten Fahrten um ca. 5 bis 15% pro Stadt erzielt werden, die mit einer überproportionalen Gewinnsteigerung einhergingen. Im Endergebnis führte die Einführung des Dynamic Pricing jedoch nicht ausschliesslich zu gestiegenen Fahrpreisen, sondern zu einer gleichzeitigen Steigerung der Auslastung. Nahezu die Hälfte der Fahrpreise wurden im Vergleich zum linearen Preismodell gesenkt und somit die Markteffizienz erhöht.

Im Zuge der Analyse konnten interessante Abhängigkeiten der Zahlungsbereitschaften und der Preise im Hinblick auf bestimmte Variablen erkannt werden, die im Einklang mit dem allgemeinen ökonomischen Verständnis ste-

hen. Beispielsweise bestand für Fahrten von und zu Banken- und Geschäftsvierteln sowie für Fahrten zum Stadtrand eine relativ hohe Zahlungsbereitschaft. Ebenfalls ist eine gewisse geografische Variation auffällig. In einigen Städten fällt die Preiselastizität der Nachfrage mit steigendem Preis stärker ab als in anderen Städten. Die Analyse lässt zahlreiche weitere Schlüsse zu, z.B. zum Effekt der Uhrzeit einer Fahrt, der Distanz und von Wetterfaktoren auf die Zahlungsbereitschaft.

Fazit und Ausblick

Die Fallstudie macht deutlich, dass moderne statistische Verfahren im Zuge des Dynamic Pricing sinnvoll eingesetzt werden können, um Erlöse und Gewinne sowie die Auslastung und Markteffizienz zu steigern. In Zukunft besteht ein beträchtliches Potenzial, Künstliche Intelligenz im Kontext einer optimalen Preispolitik in verschiedensten Branchen einzusetzen. Das konkrete implementierte Preismodell wird von Anwendungsfeld zu Anwendungsfeld verschiedene Formen annehmen und dabei auf mögliche Nebenbedingungen und marktspezifische Charakteristika (z.B.

auf die Bedeutung von Kundenbindungen, Regulierung) eingehen.

Die Fallstudie kann als beispielhafte Anwendung der Kombination von statistischen und ökonomischen Methoden betrachtet werden, die für intelligente Geschäftsentscheidungen zentral ist. Die steigende Relevanz datengetriebener Verfahren lässt sich jedoch grundsätzlich auf alle Unternehmensbereiche übertragen. Weder das Vorhandensein grosser Datensätze (Big Data) noch der Einsatz leistungsfähiger, moderner statistischer Verfahren (Künstliche Intelligenz, Machine Learning) garantieren an sich einen positiven Beitrag zum Geschäftserfolg. Erst die Kombination mit ökonomischer Theorie ermöglicht es, zu intelligenten Geschäftsentscheidungen zu kommen. Reine Prediction- und Business-Analytics basieren häufig nur Scheinkorrelationen. Zahlreiche Geschäftsentscheidungen hingegen sind auf kausale Fragestellungen zurückzuführen. Diesen kausalen Charakter zu erkennen und in der statistischen Modellierung zu berücksichtigen, ist von wesentlicher Bedeutung, um zu zielführenden Entscheidungen zu gelangen und das Geschäftsmodell eines Unternehmens nachhaltig weiterzuentwickeln. 🚩

Literatur

- Bajari, P., Nekipelov, D., Ryan, S. P. & Yang, M. (2015). Machine learning methods for demand estimation. *American Economic Review*, 105(5), pp. 481–85.
- Chernozhukov, V., Luo, Y. & M. Spindler (2019, 17. Juni). Korrelationen müssen kausal sein. *Frankfurter Allgemeine Zeitung*, S. 16.
- den Boer, A.V. (2015, 6. Januar). Dynamic pricing and learning: historical origins, current research, and new directions. *Surveys in operations research and management science*, 20(1), pp. 1–18.
- Sandhu, M. (2018, 23. Februar). The Economics of Big Tech. *Financial Times*. Abgerufen von <https://www.ft.com/economics-of-big-tech>.