

Forecasting mit Artificial Intelligence


Mit modernen Methoden der künstlichen Intelligenz können anhand enormer Datenmengen in kürzester Zeit neue Prognosen und Handlungsempfehlungen generiert werden. In der heutigen Welt, die von Komplexität und Schnellebigkeit gekennzeichnet ist, eröffnen sich so neue Perspektiven für das Forecasting.

Text — Nicole de Melo, Prof. Dr. Ing. Gerard de Melo



Nicole de Melo
ist Senior Consultant im Bereich EMEIA Financial Services bei der Ernst & Young GmbH Wirtschaftsprüfungsgesellschaft.

Planung und Forecasting sind seit jeher unabdingbar für eine effiziente Unternehmenssteuerung. Sich schnell auf Veränderungen einstellen zu können, für die Zukunft zu planen und entsprechende Maßnahmen zu treffen, hat in der aktuellen Wirtschaftslage noch einmal an Bedeutung gewonnen. Eine effektive, zeitnahe und genaue Forecast- und Planungstechnik schafft Transparenz, zeigt drohende Zahlungsunsicherheiten auf und ist ein gutes Instrument, um informierte Entscheidungen treffen zu können.



Prof. Dr. Ing. Gerard de Melo
leitet das Fachgebiet Artificial Intelligence and Intelligent Systems am Hasso-Plattner-Institut (HPI) und an der Universität Potsdam.

Zugleich lässt sich beobachten, wie Artificial Intelligence (AI, künstliche Intelligenz) in Wirtschaft und Politik als strategisch besonders wichtiges Thema zur Aufrechterhaltung der Wettbewerbsfähigkeit erkannt wird. Entsprechende Systeme, die intelligentes Verhalten an den Tag legen, erhalten bereits Einzug in den Alltag. Von automatisierten Preisanpassungen über sprachgesteuerte Produkte bis hin zu selbstfahrenden Lkws: Hintergrund der rasanten Entwicklungen in diesen Bereichen sind markante Fortschritte in der Erkennung komplexer Muster in großen Datenmengen durch rechenintensive numerische Kalkulationen. Von daher ist es naheliegend, dass AI gerade auch im Forecasting ein sehr großes

Potenzial birgt. Dieser Beitrag bietet einen Überblick zu technischen Verfahren des Forecastings mit Fokus auf aktuelle und zukünftige Anwendungsbereiche von AI. Dafür werden zunächst einfachere, klassische Verfahren eingeführt und im Weiteren verschiedene innovative Forecasting-Methoden erörtert, die einen besseren Umgang mit Volatilität, Unsicherheit, Komplexität sowie Mehrdeutigkeit versprechen.

Einfaches Forecasting

Das mit Abstand einfachste Forecasting-Verfahren ist die Annahme eines konstanten Niveaus, das auf unbestimmte Zeit weiter Bestand hat. Tatsächlich ist es in vielen alltäglichen Situationen nicht abwegig, den zuletzt beobachteten Wert als Prognose für die Zukunft heranzuziehen oder auch einen Mittelwert von vergangenen Werten zu bilden. Beispielsweise können die Verwaltungsausgaben des letzten Monats oft eine gute Basis zur Schätzung der entsprechenden Ausgaben in den darauffolgenden Monaten darstellen.

Vernachlässigt wird hier natürlich, dass es auch eine relevante Trendentwicklung geben kann wie etwa ein jährliches Wachstum. Die einfachste Methode zur Berücksichtigung eines Trends ist eine lineare Extrapolation. Hier wird zwischen

zwei Zeitpunkten die Steigung ermittelt und fortan wird angenommen, dass diese unverändert weiter bestehen bleibt, d.h. es reicht das Ziehen einer geraden Linie mit einem Lineal, um ein Forecast zu erhalten. Durch Bezugnahme auf weitere Punkte in der Vergangenheit werden die Daten belastbarer. In diesem Fall kann z.B. mittels einer linearen Regression eine optimale Gerade bestimmt werden.

Die meisten Zeitreihen haben jedoch nicht die Gestalt einer Geraden, sondern weisen eine erhebliche Volatilität auf. Darüber hinaus sollte man sich nicht zu sehr auf kurzfristige Trendentwicklungen stützen. Häufig, insbesondere im Finanzbereich, werden Daten nach Kalenderjahren organisiert. Wird jedoch anhand der täglichen Daten aus einem Jahr ein Forecasting durchgeführt, kann es leicht passieren, dass das Modell von einem Abwärtstrend im Januar ausgeht, da es zwischen den Jahren in vielen Bereichen sehr ruhig wird und die jüngsten Zahlen vom Ende des Vorjahrs dementsprechend noch stark nach unten weisen.

Saisonale und zyklische Entwicklungen

In natürlich vorkommenden Daten finden sich allerlei periodische Entwicklungen. Innerhalb eines Monats kann die Nachfrage von Waren variieren und besonders am Monatsanfang oder -ende hoch sein, wenn Gehaltszahlungen eintreffen. Auch können Quartale eine unterschiedliche Nachfrage aufweisen. So beinhaltet das vierte Quartal besonders viele umsatzstarke Tage wie „Black Friday“, „Cyber Monday“ und die Vorweihnachtszeit. Um derartiger Periodizität gerecht zu werden, kann in einfachen Fällen ermittelt werden, inwiefern die betrachtete Zeitreihe mit einer zeitlich verschobenen Version derselben Zeitreihe korreliert. Dies ist als Autokorrelation bekannt. Aufgrund wöchentlicher Regelmäßigkeiten ist z.B. bei einer Zeitdifferenz von sieben Tagen eine hohe Autokorrelation zu erwarten. Aus derartigen Betrachtungen sieht man leicht, dass Modelle herleitbar sind, die sich in jedem Schritt auf bestimmte vergangene Werte aus ausgewählten Intervallabständen beziehen, etwa dem Wert von vor einem Monat, vor zwei Monaten oder vor 12 Monaten (vgl. Abbildung 1). Dabei könnte ein einfacher Mittelwert derartiger vergangener Werte gebildet werden (Simple Moving Averages bzw. gleitende Mittelwerte). Bei einer einfachen exponentiellen Glättung hingegen werden die historischen Werte so miteinander verbunden, dass neueren Werten stets ein höheres



Moderne AI-basierte Forecasting-Techniken ermöglichen eine gemeinsame Modellierung vieler Tausender Datensätze auf mehreren Ebenen.

Gewicht zukommt als älteren. Noch verlässlicher ist eine automatisierte Gewichtung anhand der beobachteten Daten, falls sich etwa herausstellt, dass der Vorjahreswert stets eine deutlich höhere Übereinstimmung mit den aktuellen Werten bietet als der Vormonatswert. In diesem Fall wird von einer Autoregression gesprochen. Viele der bekanntesten klassischen Forecasting-Methoden basieren auf dieser Idee, darunter z.B. ARMA (Autoregressive Moving Average) sowie das darauf aufbauende ARIMA-Verfahren (Autoregressive Integrated Moving Average).

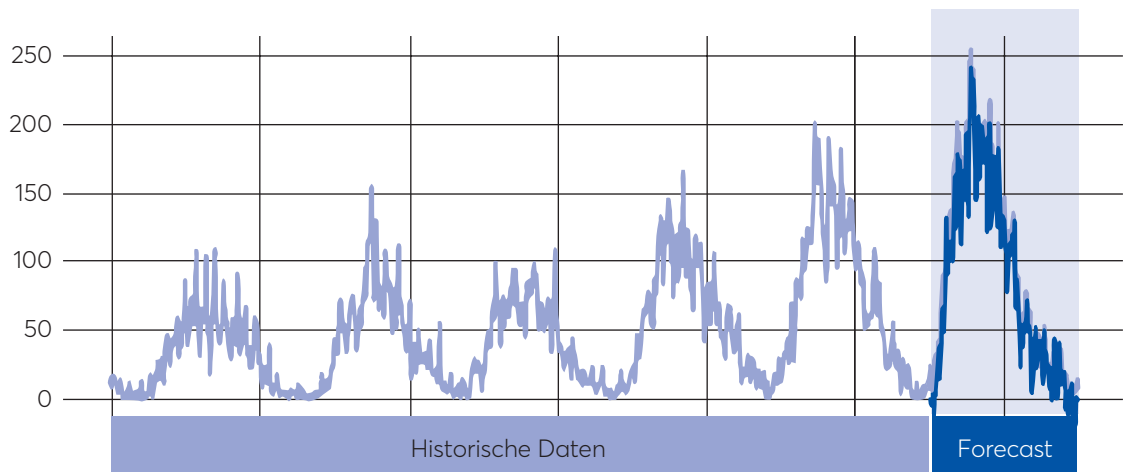
Viele Daten sind nicht ganz so regelmäßig, wie man es sich vielleicht wünscht. So können verschiedene Konjunkturzyklen unterschiedliche Charakteristika aufweisen und gewisse kurze Perioden können von einer besonders hohen Volatilität gekennzeichnet sein. Wünschenswert sind im Allgemeinen Verfahren, die auch eine Überlagerung heterogener Trends und Schwankungen sowie Trendwenden identifizieren können. Wenn hinreichend viele historische Daten vorhanden sind, können derartige Phänomene eventuell auch automatisch durch verschiedene Komponenten eines Modells erfasst werden. In der Fachliteratur finden sich daher zahlreiche Versuche, neue Modelle zu entwerfen, die mit Überlagerungen und anderen speziellen Phänomenen besser zurechtkommen sollen. Einige klassische Verfahren sind teilweise noch in regulären Tabellenkalkulationsprogrammen durchführbar (z.B. Holt-Winters- bzw. Error-Trend-Seasonality-Ansatz, GARCH und Croston-Modell).

Anomalien

Besonders zu beachten sind so genannte Ausreißer oder Anomalien. Diese können Folge einmaliger Ereignisse sein, wie z.B. ein Taifun, der sich auf die Supply Chain auswirkt, oder aber auch

ARMA und ARIMA sind weit verbreitete Verfahren zum Forecasting von Zeitreihen. Sie verwenden einerseits vergangene Werte aus der Zeitreihe (Autoregressionskomponente), andererseits auch vergangene Schätzfehler (Moving-Average-Komponente). Im Unterschied zum ARMA-Verfahren kann bei ARIMA darüber hinaus noch eine Differenzbildung erfolgen, so dass die Modellierung sich nicht direkt auf die ursprünglichen Zeitreihenwerte bezieht, sondern stattdessen Differenzen zwischen aufeinanderfolgenden Zeitreihenwerten vorhergesagt werden.

Abbildung 1: Forecasting unter Berücksichtigung einer periodischen Regelmäßigkeit sowie eines Wachstumstrends



fehlerhafte Einträge, wenn etwa versehentlich eine Ziffer zu viel eingetippt wurde. Zwar sind außergewöhnliche und überraschende Ereignisse naturgemäß kaum vorhersehbar, jedoch sollte das Forecasting damit umgehen können, falls sich in der Vergangenheit ungewöhnliche Datenpunkte vorfinden. Eine Möglichkeit, dies zu berücksichtigen, ist eine gesonderte Erkennung derartiger Ausnahmepunkte bzw. -phasen. Diese können dann bei nachfolgenden Berechnungen herausgenommen werden oder durch typische Werte ersetzt werden.

Selbstverständlich kann es auch für das operative Geschäft wichtig sein, ungewöhnliche Vorkommnisse in historischen und auch in aktuellen Daten zu identifizieren, etwa ein erhöhtes Supportaufkommen oder Unregelmäßigkeiten im Cashflow. Zur Erkennung von Anomalien gibt es unzählige Verfahren.¹ Beziehen können sich diese z.B. auf die Dichte, d.h. der allgemeinen Anzahl ähnlicher Datenpunkte, oder auch auf die Abweichung von zeitlich nahen Datenpunkten sowie die Abweichung von erkannten Trends und Periodizitäten.

Big Data

Eine noch bessere Reaktion auf Ereignisse kann durch die Einbindung großer Datenmengen

erzielt werden. Besonders ausschlaggebend für den Erfolg des Forecastings sind zunächst die zur Verfügung stehenden historischen Daten. Im Allgemeinen hilft es, wenn die Daten einen möglichst großen Zeitraum abdecken, sofern diese zumindest in einigen wesentlichen Grundzügen den aktuellen Daten ähneln, damit entsprechende Muster identifiziert bzw. Hypothesen über die Daten besser validiert werden können.

Darüber hinaus kann es von großem Vorteil sein, viele Datenreihen ähnlichen Typs zu modellieren, wenn etwa gleichwertige Kennzahlen in jeder Region oder in jeder Filiale gesammelt werden können. In der künstlichen Intelligenz ist die Verfügbarkeit großer Datenmengen, auch Big Data genannt, oftmals das A und O, da gewisse komplexe Zusammenhänge erst dann erkennbar werden. Entsprechend bietet es sich auch im Forecasting an, sofern viele ähnliche Datensätze vorliegen, nicht völlig separate Modelle für jede einzelne Region zu erstellen, sondern einen Lernmechanismus einzusetzen, der die Gesamtheit dieser Daten analysiert, um ein robusteres und flexibles Modell zu schaffen, das sich auf deutlich mehr Erfahrungswerte berufen kann. Oftmals gibt es auch signifikante Bezüge zwischen einzelnen Zeitreihen. So kann die Markteinführung eines viel beworbenen, neuen Produkts in allen Regionen zugleich zu einem entsprechenden Bedarf führen. In der Ökonometrie hat sich anhand dynamischer Faktor-Modelle gezeigt, dass zahlreiche

¹ Vgl. den Überblick bei Chandola/Banerjee/Kumar, ACM Computing Surveys 3/2009.

Tabelle 1: Vergleich zwischen klassischem und AI-basiertem Forecasting

	Klassisches Forecasting	AI-basiertes Forecasting
Anzahl Zeitreihen pro Modell	Betrachtung einer einzelnen oder einiger weniger Zeitreihen	gleichzeitige Modellierung Tausender Zeitreihen möglich
Exogene Daten	keine oder nur minimale Berücksichtigung	umfassende Einbeziehung großer Datenmengen
Analyse von unstrukturierten Daten (Texte, Bilder, Videos)	nicht möglich	umfassende Möglichkeiten
Modellierung komplexer Sachverhalte	begrenzt möglich	erweiterte Möglichkeiten
Komplexität	Modelle sind verhältnismäßig einfach interpretierbar	erhöhte Komplexität, langsamer Trend zu verständlicheren Modellen
Reaktionsgeschwindigkeit	teilweise langsam aufgrund manueller Prozesse	teilweise langsam aufgrund manueller Prozesse, jedoch Trend zu Echtzeit-Monitoring

recht diverse makroökonomische Entwicklungen auf eine kleine Anzahl von latenten Faktoren zurückführbar sein können. Moderne AI-basierte Forecasting-Techniken ermöglichen eine gemeinsame Modellierung vieler Tausender Datensätze auf mehreren Ebenen, etwa Absatzzahlen in Regionen sowie in einzelnen Filialen, zugleich aber auch nach Produktkategorien sowie individuellen Produkten, in einem einzigen Gesamtmodell.

Während saisonale Schwankungen unmittelbar als Regelmäßigkeiten erkennbar sind, gibt es auch Entwicklungen, die auf den ersten Blick relativ willkürlich wirken und erst mit dem nötigen Hintergrundwissen über die Marktlage oder über besondere Ereignisse erklärbar werden. Hier können weitere Informationen aus zusätzlichen Quellen eingebunden werden. Diese aus Sicht der Modellierung exogenen Daten können durchaus auch unternehmensinterne Daten sein, wie etwa Informationen zur zukünftigen Auftragslage aus verschiedenen Divisionen oder zu geplanten Großinvestitionen. Es kann sich aber auch um gänzlich externe Daten handeln, wie Prognosen zur Entwicklung der Wirtschaft in einem Drittland oder der entsprechenden Wechselkurse. Wetterdaten zum Beispiel haben Einfluss auf Energiepreise und Verbraucherverhalten. Auch ganz banale Fakten wie Schulfreienterminen oder

jährliche variierende Feiertage wie Ostern können dem Forecasting dienlich sein.

Durch die fortschreitende Digitalisierung sind Daten verschiedenster Art in zunehmendem Maße verfügbar. Damit sie jedoch zum Einsatz kommen können, ist zunächst eine integrierte Dateninfrastruktur wichtig. Systeme müssen miteinander verbunden sein, damit auf alle relevanten Quellen zugegriffen werden kann. Nicht nur ERP- und CRM-Systeme, sondern auch diverse in einzelnen Unternehmensbereichen eingesetzte Spezialsoftware müssen eingebunden werden, damit relevante Informationen nicht erst per Anfrage an entsprechende Teams in Form eines E-Mail-Anhangs eintreffen. Um solche langwierigen Prozesse zu vermeiden, hat sich in den letzten Jahren auch das Konzept des Data Lakes durchgesetzt, bei dem unternehmensweite Daten aus verschiedenen Abteilungen in einen zentralen Speicher fließen und so unmittelbar zur Analyse bereitstehen. Generell gilt, dass bei jeder Verarbeitung oder Speicherung von Daten die entsprechenden datenschutzrechtlichen Vorgaben zu beachten sind.

Bevor die vorhandenen Rohdaten zu Forecast-Zwecken genutzt werden können, erfolgen meist zunächst weitere Vorverarbei-

tungsschritte, wie etwa Data Cleaning und Data Integration, damit alle relevanten Informationen für einen bestimmten Zeitraum im selben Format vorliegen. Hier können diverse Optimierungen erfolgen, damit diese Schritte möglichst schnell und automatisiert ablaufen. Ein Stichwort dabei ist Robotic Process Automation (RPA), bei dem stark strukturierte und sich wiederholende Prozesse eines Unternehmens automatisiert werden.

Machine Learning und Predictive Analytics

Sobald große Datenmengen der oben genannten Art ins Spiel kommen, können Machine Learning und Predictive Analytics eingesetzt werden. Das Machine Learning (Maschinelles Lernen) ist eine wesentliche Komponente von AI, bei der es um Systeme geht, deren Verhalten nicht komplett durch entsprechende Programmierung vorbestimmt ist, sondern teilweise erst anhand von Daten erlernt wird. Predictive Analytics bezieht sich dabei auf den Einsatz solcher Verfahren zur Vorhersage zukünftiger Entwicklungen.

Im Bereich des Machine Learnings gibt es verschiedene Techniken, die sich mit der Analyse von Daten und dem Durchführen von Forecasts beschäftigen. Einige Verfahren erkennen Gruppierungen, Muster und Zusammenhänge, z.B. in Form von Cluster- oder Assoziationsanalysen. Am weitesten verbreitet ist das überwachte Lernen, das Trainingsdaten als Beispiele für das zu erlernende Verhalten heranzieht oder Fortschreibungen von historischen Daten erzielt. Dabei werden bei Regressionsanalysen Zahlen ermittelt, während bei Klassifizierungsproblemen Zugehörigkeiten zu vordefinierten Klassen bestimmt werden, z.B. ob ein großes Kreditausfallrisiko besteht.

Im Vergleich zu klassischen statistischen Algorithmen haben viele moderne Verfahren (z.B. Entscheidungsbäume mit Gradienten-Boosting) den großen Vorteil, dass sie ohne Weiteres mit vielen Tausenden Variablen zurechtkommen und so externe Daten unterschiedlichster Art verwerten können, etwa Rohstoffpreisindizes, Konsumklimadaten, aber auch Produktrezensionen und Schlagzeilen. Dies ermöglicht genauere Forecasts, die nicht lediglich die Ist-Entwicklung widerspiegeln, sondern schnell auf veränderte Rahmenbedingungen reagieren können.

Große Datenmengen auszuwerten und mittels Machine Learning Vorhersagen abzuleiten, ist

eine große Herausforderung, die für Unternehmen aber eine große Hilfe zur Entscheidungsfindung darstellt. In jüngster Zeit sind auch zunehmend Cloud-Dienste in den Vordergrund gerückt, die diesen Schritt erleichtern können. Planungsrelevante Informationen können u.U. in Echtzeit analysiert und es können eigene Szenarien und Trendanalysen erstellt werden. Dabei sind die Aspekte der Datensicherheit und Datensouveränität besonders zu beachten.

Deep Learning

Deep Learning ist heutzutage in aller Munde und ein Thema, dem sich sogar der kanadische Premierminister Justin Trudeau in einem Online-Video widmet.² Zwar kann die künstliche Intelligenz als Forschungsgebiet eine jahrzehntelange Geschichte aufweisen, sie hat aber erst in den letzten Jahren besonderen Auftrieb bekommen. Maßgeblich dazu beigetragen haben die durch Deep Learning erzielten Fortschritte im Umgang mit hochkomplexen Daten, aus denen sich sonst nicht ohne Weiteres Zusammenhänge ableiten lassen. Diese ermöglichen eine Auswertung von Bild- und Videomaterial oder gar eine Generierung neuer Daten, etwa Bilder im Stil von Seurat oder Monet. Letzten Endes ist Deep Learning jedoch lediglich ein Rebranding der altbekannten künstlichen neuronalen Netze, die bereits seit vielen Jahrzehnten im Machine Learning erforscht werden. Hierbei handelt es sich um mathematische Modelle, die in einigen Grundzügen von menschlichen Gehirnzellen inspiriert, jedoch konzeptuell deutlich einfacher gestaltet sind. Durch stärkere Rechner mit ursprünglich primär für Gaming-Zwecke entwickelten Grafikprozessoren zur schnelleren Matrizenrechnung sowie geringfügigen methodischen Verbesserungen kam es erst in den letzten 15 Jahren zu besonders großen Durchbrüchen.

Für das Forecasting besonders relevant sind auf Sequenzen spezialisierte Varianten, die für jeden Zeitschritt eine weitere Vorhersage liefern (insbesondere Recurrent Neural Networks, Long-Short-Term-Memory-Modelle und die so genannte Transformer-Architektur). Diese Modelle sind sogar in der Lage, einen angefangenen Text im gleichen Stil und grammatikalisch

² Vgl. University of Toronto, Konferenz „Machine Learning and the Market for Intelligence“ 2017, Videomitschnitt unter: <https://youtu.be/yPcDfKqg1g> (Abruf: 16.02.2021).

Deep Learning ist ein Teilbereich des Machine Learnings und nutzt vielschichtige künstliche neuronale Netze, die sich nach der Funktionsweise menschlicher Gehirnzellen richten. Unter Ausnutzung großer Datenmengen werden die Parameter eines Netzes immer weiter angepasst, bis es in der Lage ist, eigene Prognosen zu liefern.

Gradienten Boosting setzt viele kleine Einzelmodelle ein, um eine möglichst gute Gesamtvorhersage zu erzielen. In jedem Lernschritt wird dabei ein neues Einzelmodell hinzugefügt, das den noch verbleibenden Fehler der bisherigen Modelle korrigieren soll. So kann eine immer bessere Annäherung an die Zielwerte erreicht werden. Als Einzelmodelle kommen typischerweise Entscheidungsbäume zum Einsatz.

weitgehend einwandfrei weiterzuschreiben, z.B. auch im Stil von Shakespeare, jedoch inhaltlich nicht unbedingt immer kohärent. Um sie für Forecasting-Zwecke einzusetzen, bietet es sich an, ihre Struktur so zu erweitern, dass auch auf weiter in der Vergangenheit zurückliegende Daten unmittelbarer Zugriff besteht. Ebenfalls kann das Forecasting zugleich auf mehreren Stufen durchgeführt werden, z.B. auf Tagesebene sowie auf Monatebene, damit längerfristige Entwicklungen konkreter modelliert werden. Daneben entstehen in jüngster Zeit auch gänzlich neue Deep-Learning-Modelle, die noch spezieller dem Forecasting gewidmet sind³, so z.B. Deep-Learning-Varianten statistischer Verfahren zur Berücksichtigung besonders schwer erkennbarer Faktoren, Varianten mit einer direkteren Vorhersage der Unsicherheit sowie besondere Residual-Architekturen, mit denen schrittweise versucht wird, den verbleibenden Restfehler besser zu modellieren.

Besonders geeignet sind Deep-Learning-Modelle auch beim Interpretieren unstrukturierter Daten. Text Analytics bezieht sich etwa auf die Analyse von Konzernberichten oder Nachrichtentexten. Wenn beispielsweise der Bedarf an medizinischen Geräten aufgrund von COVID-19 rasant ansteigt, dann ist dies nicht direkt aus den historischen Daten ersichtlich. Anhand sozialer Medien sind aber neue Phänomene auch in weit entfernten Märkten frühzeitig erkennbar. Dies könnten spezifische Produktankündigungen sein oder auch allgemeine Trends, die sich etwa auf das dortige Konsumklima auswirken. Computer Vision hingegen ermöglicht eine Analyse von Bild- und Videomaterial und erlaubt so Rückschlüsse etwa auf Handelsströme in Häfen oder gibt anhand von Satellitenaufnahmen Aufschluss über Konjunkturentwicklungen.

Augmented Analytics und Explainable AI

Vorhersagen über die Praxis des Vorhersagens sind naturgemäß nicht einfach. Dennoch kann man anhand jüngerer Entwicklungen im Rahmen der künstlichen Intelligenz einige Tendenzen ableiten. Generell gibt es zu gegebenen Daten unendlich viele Modelle, die mit diesen Daten vereinbar sind und so müssen immer gewisse Annahmen getroffen werden, welche dieser

Modelle zu bevorzugen sind. Dafür benötigt wird Personal mit Wissen um das konkrete Unternehmensumfeld sowie einer entsprechenden Vertrautheit mit den Daten, zugleich aber auch mit mathematischen und technischen Kenntnissen im Bereich Forecasting. Aufgrund dieser doppelten Anforderungen kann entsprechend qualifiziertes Personal rar sein, vor allem wenn AI-Erfahrung benötigt wird. In den letzten Jahren haben sich daher Forschende im Bereich Machine Learning und AI verstärkt zum Ziel gesetzt, sich gewissermaßen selbst zu automatisieren. Unter den Begriffen Auto-ML und Augmented Analytics fallen dabei Techniken, die die typischen bei der Modellierungsarbeit anfallenden Aufgaben selbstständig durchführen oder zumindest dem Menschen die Arbeit erleichtern. Dazu kann eine automatisierte Wahl zwischen verschiedenen Modellierungsvarianten gehören oder eine automatische Evaluierung des Modells sowie ein automatisches Durchprobieren vieler potenzieller Hypothesen.

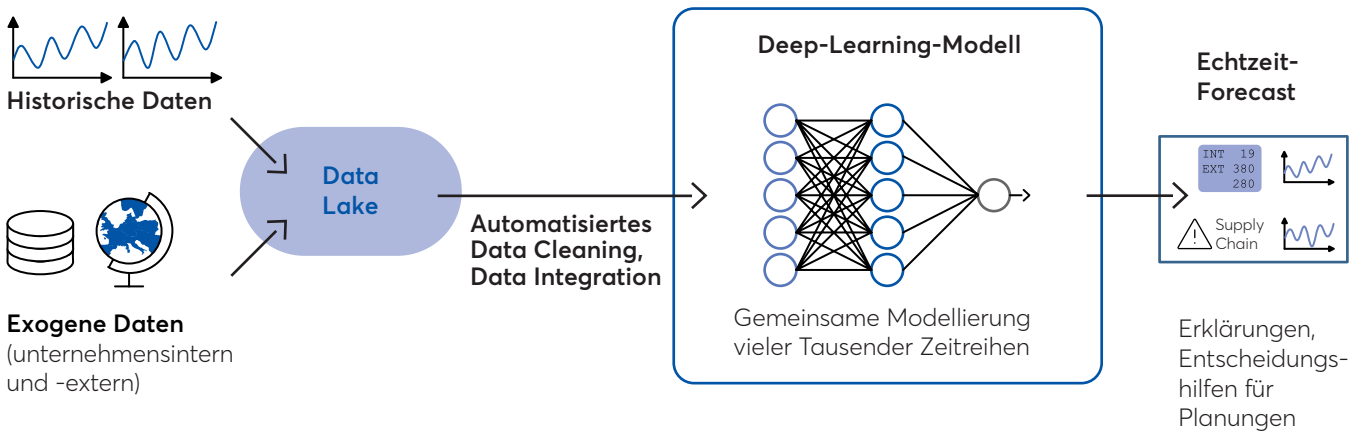
Hinzu kommt auch ein Trend zum Explainable AI, d.h. zu Verfahren, die nicht nur die eigentlichen Vorhersagen liefern, sondern auch dazu passende Erklärungen sowie Aussagen bezüglich eventueller Unsicherheiten. Im besten Fall sind diese Aussagen auch ohne AI-Kenntnisse unmittelbar verständlich und ermöglichen eine einfache Anpassung des Modells, so dass unpassende Prognosen hinterfragt und korrigiert, aber auch zusätzliche Annahmen leichter integriert werden können. Je mehr Daten dem System geliefert werden, desto größer ist die Wahrscheinlichkeit, dass relevante Informationen vorhanden sind, die das Modell ausnutzen kann. Allerdings muss man bedenken, dass dies auf eine Suche nach der Nadel im Heuhaufen hinauslaufen kann, wenn in diesem Konglomerat auch viele irrelevante Daten vorkommen. Korrelationen können bekanntermaßen auch rein zufällig sein. Schaut man sich etwa an, wie oft in den USA die Doktorwürde im Bereich Soziologie verliehen wurde, so zeigt sich zumindest für den Zeitraum 1997 bis 2009 eine sehr starke Korrelation mit der Anzahl der weltweiten nichtkommerziellen Raumflüge.⁴ Automatisierte Algorithmen können leicht auf solche zufälligen Zusammenhänge hereinfliegen, so dass ein vorsichtiger Einsatz geboten ist, insbesondere

Computer Vision ermöglicht Computersystemen eine inhaltliche Auswertung von Bild- und Videomaterial. Dabei werden zunächst grundlegende Kanten und Muster erkannt und darauf aufbauend allmählich auch komplexere Objekte oder auch Geschehnisse identifiziert. Oft kommen Deep Learning-Modelle mit speziellen Filtermasken zum Einsatz, so genannte Convolutional Neural Networks.

³ Vgl. z.B. Makridakis/Spiliotis/Assimakopoulos, International Journal of Forecasting 2020, S. 54–74.

⁴ Vgl. Vigen, Spurious Correlations, 2021, <https://tylervigen.com/spurious-correlations> (Abruf: 16.02.2021).

Abbildung 2: Überblick über die dargestellten Methoden des Forecastings



wenn ethisch bedenkliche Herleitungen möglich sind. Erst wenn ein System seine Vorschläge mit überzeugenden Argumenten untermauern kann, sollten Entscheidungsträger bereit sein, diesen zu vertrauen.

Continuous Intelligence und Entscheidungshilfen

Von den oben genannten Analysen können Maßnahmen und Entscheidungen hinsichtlich der weiteren Planung getroffen werden bzw. es können vorhandene Planungen durch die Ergebnisse der Forecast-Analysen präzisiert werden. Gerade anhand von Entwicklungen wie COVID-19 zeigt sich eine Notwendigkeit, die Planung dynamisch an aktuelle Geschehnisse anpassen zu können. Das beinhaltet ein Design von Systemen, bei denen derartige Planungsprozesse nicht erst vom zuständigen Personal initiiert werden, sondern die automatisch eine stetige Echtzeit-Observierung relevanter Marktsignale und eine ständige Neuberechnung der Prognosen beinhalten. Ferner werden die aus unterschiedlichen Bereichen stammenden Teilpläne in einem einzigen System zusammengebracht.

Durch diese Echtzeitintegration und -modellierung kann nicht nur anhand von Dashboards ein mögliches Verfehlen von Zielvorgaben frühzeitig erkannt werden. Das System sollte auch Abweichungen von bisher angenommenen Rahmendaten erkennen und idealerweise auch neue Trends antizipieren, die sich in Finanzmärkten oder sozialen Medien abzeichnen. Bei sich rapide verändernden

Prognosen kann die Software dann frühzeitig entsprechende Hinweise liefern und womöglich auch Handlungsempfehlungen ableiten, etwa Anpassungen in der Lieferkette oder bei der Personalplanung. Simulationen verschiedener Fallszenarien können als Entscheidungshilfe dienen, z.B. wie sich neue Marketingmaßnahmen oder eine veränderte Produktstrategie auswirken könnten. Abbildung 2 zeigt den Zusammenhang zwischen den dargestellten Methoden im Überblick.

Fazit

In der Planung und beim Forecasting ist es entscheidend, aus vorhandenen Daten Erkenntnisse über potenzielle zukünftige Entwicklungen abzuleiten. Dies sind die Stärken moderner AI-Methoden wie Deep Learning, die dabei mit hoher Geschwindigkeit gewaltige Datenmengen analysieren können. Gerade die Erfahrungen in der Pandemie zeigen, dass in unserer modernen vernetzten Welt vieles miteinander zusammenhängt und Erscheinungen in sehr fernen Märkten sich recht bald auch auf das örtliche Kerngeschäft auswirken können. Aktuelle Forschungsergebnisse weisen auf ein sehr hohes Potenzial von AI und Machine Learning hin, um schnellere, detailliertere und präzisere Forecasts zu liefern. Eine Umsetzung moderner AI-Lösungen muss jedoch mit Bedacht erfolgen und ist derzeit in vielen Situationen noch nicht praktikabel. Da diese Lösungen aber zunehmend auch Eingang in moderne Unternehmenssoftware finden, zeichnet sich ein klarer Trend zu einem wachsenden Einsatz von AI in Planung und Forecasting ab. ■