

Machine Learning in der Industrie

Mit Automatisierung Qualität steigern

Inhalt

Einführung	3
Qualitätsmanagement, Lieferketten und Arbeitsschutz	6
So kommt KI schnell und effizient in die Praxis	13
Die Industrie hat bei KI spezifische Bedarfe	16
Fazit	20
Über AllCloud	21



Einführung

Mittlerweile gibt es eine ganze Reihe von industriellen Anwendungsfällen, in denen sich mit Machine Learning (ML) und Künstlicher Intelligenz (KI) die Prozesseffizienz deutlich steigern lässt. Das gilt vor allem für Bereiche wie Qualitätskontrolle und die Steigerung der Overall Equipment Efficiency. Anders als in den letzten Jahren ermöglichen auf die Industrie zugeschnittene neue Cloud-ML-Services den Einstieg auch ohne eigene Data-Science-Ressourcen.

Den Einstieg ins maschinelle Lernen finden

Dass sich durch den Einsatz von Machine Learning und KI-Algorithmen in der industriellen Praxis zusätzliche Effizienzpotenziale – auch in bereits stark digitalisierten und automatisierten Umfeldern – erschließen lassen, wissen bereits viele Unternehmen. Dennoch läuft die Integration dieser Technologien bisher nur zögerlich an. Die Ursachen dafür sind vielfältig: Da ist zum einen die Unübersichtlichkeit am Markt, der Mangel an Datenwissenschaftlern und die sehr vielfältigen Ansätze und Tools.

Selbst dort, wo schon erste ML-Projekte laufen, kommt die Nutzung in der Breite kaum vom Fleck. Oft gibt es nur einen Proof of Concept. Gerade im wohl prominentesten Anwendungsszenario, der vorausschauenden Wartung, sind kaum produktive Anwendungen im Einsatz, geschweige denn Lösungen, die über eine Vielzahl von Maschinen hinweg skaliert wurden. Zu Beginn des KI-Trends vor einigen Jahren war oft zu hören und lesen, dass die Unternehmen einfach mit KI experimentieren sollten. Für den produktiven Einsatz in der Fertigung beispielsweise

wurde jedoch regelmäßig festgestellt, dass es so einfach dann doch nicht ist. Zwar lohnt es sich, KI-Technologien am Anfang ein bisschen auszuloten, um ein Gefühl für die Möglichkeiten zu bekommen: Dieser Ansatz reicht allerdings nicht aus, um Machine Learning in den produktiven Betrieb zu bringen.

Mittlerweile hat sich jedoch einiges verändert. Es gibt skalierbare, flexible Cloud-Plattformen und Lösungen in Form von Machine-Learning-Services. Sie vereinfachen die Umsetzung in der Praxis erheblich. Trivial ist ML damit allerdings immer noch nicht: Es braucht weiterhin auch die richtigen Prozesse und qualifizierte Dienstleister, um Anwendungen erfolgreich umzusetzen und aus einer Vielzahl von Werkzeugen das richtige Tool zum richtigen Zeitpunkt zu wählen. Managed Service Provider halten der Unternehmens-IT den Rücken frei, damit Budgets und Ressourcen für Innovation genutzt werden können: Auch bei den Lösungen aus der Cloud sollten intelligente Kostenoptimierung und -kontrolle im Vordergrund stehen.

Definition: Machine Learning, KI, Deep Learning

Machine Learning

Zum Thema Machine Learning zählen ganz pragmatisch alle datengetriebenen Ansätze zur Erkennung von Mustern, die Vorhersagen auf Basis von historischen Fakten extrapolieren.

Künstliche Intelligenz (KI)

Machine Learning ist eine Untergruppe der Künstlichen Intelligenz (KI). KI bedeutet, einem Computer beizubringen, dass er menschliches Verhalten auf irgendeine Weise nachahmt.

Deep Learning

Deep Learning ist eine Untergruppe des Machine Learning und basiert auf Künstlichen Neuronalen Netzwerken: Beispielsweise in der Bild- und Spracherkennung oder der Robotersteuerung. ML dient in diesem White Paper als Sammelbegriff für Algorithmen und Modelle, die auf Datengrundlage trainiert werden und oft selbsttätig dazulernen.



Typische Stolpersteine vermeiden

Gerade KI-Projekte können leicht scheitern, wenn die nötigen Vorbereitungen fehlen. Zunächst gilt es, den Anwendungsfall sorgfältig zu definieren und die Frage zu klären, ob er überhaupt auf der Basis von Daten lösbar ist. Zudem sind die richtigen Tools, Kompetenzen und Daten wesentlich. Wenn die Datenlage nicht stimmt, wird es regelmäßig schwierig – und hier haben viele Unternehmen noch Nachholbedarf. Denn ohne barrierefrei vorhandene Daten geht es perspektivisch nicht, meinen Experten: Eine Deep-Learning-Lösung ist dann wie ein superschneller BMW, aber ohne Autobahn. Sogenannte “Data Tastings” bzw. “Data Discovery” durch Spezialisten helfen am Anfang dabei, die Datenlage zu klären. Grundsätzlich gilt: Eine agile Projektmethodik eignet sich am besten für das oft iterative Vorgehen bei der Entwicklung von ML-Anwendungen.

Bei der Definition des Anwendungsfalls sollte auch geklärt werden, ob es wirklich KI sein muss, oder ob nicht auch eine simplere Methode helfen kann. Der Ablauf ist also, vom Problem auszugehen: Die größten Pain-points zu identifizieren und zu klären, ob dazu Daten vorhanden sind, anstatt vom KI-Einsatz als Selbstzweck auszugehen – das wäre die falsche Richtung. Auch eine zu hohe Erwartungshaltung, die sich im KI-Umfeld oft durch eine Überschätzung von Technologie einstellt, kann sich ebenfalls als Hürde erweisen, die den Blick auf die Realität verstellt. Ganz wichtig ist also, den Scope richtig zu wählen und im Auge zu behalten – es empfiehlt sich, klein am konkreten Use Case zu starten, aber dennoch von Anfang die Industrialisierung strategisch im Blick zu haben.

Kompetenzmangel und Datenprobleme bremsen ML aus

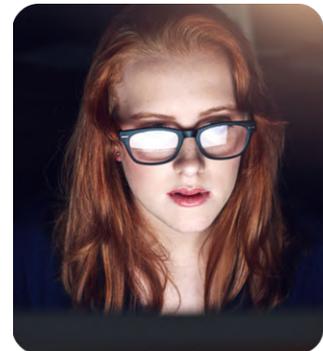
65 Prozent der Mittelständler schätzen Kompetenzmangel, 52 Prozent Implementierungshürden und mehr als die Hälfte Datenprobleme als größte Hürden für KI ein. Das ergab die aktuelle Deloitte-Studie „Künstliche Intelligenz im Mittelstand“, für die 307 Entscheider aus mittelständischen Betrieben befragt wurden. Für den aktuellen Betrieb wird KI-Technologie demnach zurzeit nur eingeschränkte Bedeutung zugemessen. Andererseits prognostizieren 59 Prozent eine Zunahme oder sogar starke Zunahme an Bedeutung. Unternehmen mit hohem digitalen Reifegrad und ersten Praxisprojekten sehen zu hundert Prozent eine hohe Relevanz von KI jeweils für Prozessautomatisierung und Dateneffizienz.

Qualitätsmanagement, Lieferketten und Arbeitsschutz: ML bietet vielfältiges Optimierungspotential

In vielen Bereichen, wie bei Webprozessen in der Textilindustrie, hilft eine kontinuierliche ML-basierte Qualitätsüberwachung, bei einem Fehler rechtzeitig einen Schritt zurück zu gehen. Sie trägt auch dazu bei, fehlerhafte Ware frühzeitig auszusortieren, anstatt später enormen Aufwand in weitere Prozessschritte investieren zu müssen. Das ist unter anderem in der chemischen Industrie und in der Getränkeherstellung der Fall, wo bereits früh im Prozess vor Verpackung und Abfüllung beispielsweise Verunreinigungen erkannt werden müssen. Mit entsprechenden Anwendungen kann aber auch in der Elektronikherstellung geprüft werden, ob Lötprozesse fehlerfrei und Steckverbindungen korrekt sind. Auch Sortierprozesse können so automatisiert werden. Selbst in Kontexten wie dem Arbeitsschutz und der Logistik gibt es zahlreiche Einsatzmöglichkeiten. Lageroptimierung, Schwundanalyse oder Estimated Time to Arrival sind typische Anwendungsfälle in der Logistik, bei denen sich mit Machine Learning oder KI-Ansätze Effizienzpotenziale heben lassen.

Allrounder: Visuelle Qualitätskontrolle

Bei der visuellen Qualitätskontrolle kommen verstärkt Bilderkennungs-Anwendungen zum Einsatz, die zum Beispiel anhand einer Oberflächenanalyse auf Kratzer und Dellen prüfen oder kontrollieren, ob alle Bestandteile einer Baugruppe vorhanden sind. Diese Überprüfung wird in der Regel von Mitarbeitern mit geschultem Auge durchgeführt, die zum Beispiel erkennen, ob eine Lackierung gelungen ist. Auch Algorithmen können kleine Abweichungen tolerieren, wie es ein Mensch tun würde. Sie lernen, den Spielraum zwischen akzeptabel und inakzeptabel anhand entsprechender Bilder zu interpretieren. Entsprechende Systeme erzielen eine hohe Genauigkeit und Fachmitarbeiter können sich auf andere wichtige Tätigkeiten konzentrieren.



Praxisbeispiel 1: Qualitätserkennung in der Chip-Herstellung

Beim Chip-Hersteller TowerJazz Semiconductor werden mittels Fotolithografie Chips auf Siliziumscheiben, sogenannte Wafer, eingeprägt. Für die Halbleiterherstellung gibt es bereits sehr komplexe Produktionsstraßen, in denen digitale Qualitätsüberwachung eine wichtige Rolle spielt: Schließlich ist die manuelle Kontrolle bei so kleinen Chips schwierig. Dennoch wollte der Hersteller die Qualitätskontrolle weiter optimieren. Trotz der digitalen Herangehensweise wurden zwar Daten erhoben, aber noch nicht für Machine Learning verwendet, sondern lediglich nach einem Regelwerk bewertet. Ziel war eine selbstlernende Lösung mit Amazon SageMaker, dazu wurde AllCloud von TowerJazz Semiconductor beauftragt.

Für die selbstlernende Lösung wurden die Wafer-Fotos aus der Produktionsstraße abgegriffen und dem Algorithmus vorgelegt. Dabei gab es fünf unterschiedliche Bewertungsklassen von schlecht und gut. Die Ergebnisse von ML-Algorithmen verbessern sich mit der Menge der Trainingsdaten, deshalb nutzte man Datenaugmentierung: Eine Reihe von Techniken, mit denen die Größe eines Datensatzes durch Transformation der vorhandenen Daten künstlich erhöht werden kann. Beispielsweise werden dabei Bilder horizontal oder vertikal gespiegelt, anders zugeschnitten oder gedreht. So konnte das Modell seine Genauigkeit verbessern. Während zuvor durch Prozessoptimierung die Fehlerquote bereits auf 21 Prozent gesenkt werden konnte, gelang mit ML eine sehr deutliche weitere Reduktion auf zwei Prozent.



Predictive Maintenance

In der Serienfertigung kommt die Produktion hin und wieder aufgrund vermeidbarer Verschleißprobleme zum Erliegen. Oft entsteht daraus ein erheblicher finanzieller Schaden. Wenn Unternehmen an das Thema maschinelles Lernen und KI herangehen, lohnt sich daher immer eine gezielte Analyse, wie und an welcher Linie teure Bandstillstände häufiger vorkommen. Ein typisches Beispiel ist der rechtzeitige Austausch von Roboter-Schweißzangen. Die Analyse von Temperatur- oder Frequenzprofilen von Werkzeugmaschinen oder Turbinen trägt dazu bei, Ausfälle durch rechtzeitige Wartung zu vermeiden.

Dort, wo es zum Beispiel um Vorhersagen geht, wann Geräte oder Maschinen

ausfallen oder fehlerhaft funktionieren, braucht es historische Beispiele, die solche Zustände in den Maschinendaten und möglichst auch den Servicedaten abbilden – während des Problems und in der Anbahnungsphase davor. Wenn sie fehlen oder nicht gesammelt werden, sind möglichst frühzeitige Vorhersagen eines drohenden Fehlers schwierig. In der Praxis erreichen die ML-Algorithmen rund um Predictive Maintenance oft sehr erfolgreiche Werte: Teilweise lassen sich Ausfälle bis zu einer Woche im Vorfeld sehr gut vorhersagen. Gerade bei so rechtzeitigen Prognosen können dann gegebenenfalls auch gleich zusammen mit der Fehlervermeidung weitere geplante Wartungsmaßnahmen vorgezogen werden.

Anomalie-Erkennung als zuverlässiges Frühwarnsystem

Ein typisches Instrument ist die Anomalie-Erkennung, mit der erfasst wird, ob es Ausreißer gibt und Schwellenwerte überschritten werden. Die Daten, die über die Zeit hinweg entstehen, werden auf dieser Basis klassifiziert. Wenn der Wert über einem gewissen Schwellenwert liegt, ist das ein Anzeichen dafür, dass es einen Fehler

geben könnte. Wichtig ist deswegen die genaue Betrachtung über längere Zeiträume sowie eine Mindestmenge an brauchbaren und aussagekräftigen Daten. Nur so kann ein Algorithmus wirklich zuverlässig beurteilen, ob eine Über- oder Unterschreitung eines Wertes überhaupt zu einem Fehler führen wird.

Digital Twin steht kurz vor dem Durchbruch

In einigen Branchen wie der Auto-industrie wird das Thema Digitaler Zwilling des Produkts und seiner Produktion immer dringlicher. Bei der Umsetzung gibt es jedoch noch viele Herausforderungen, die ohne ML und datengetriebene Modelle entlang des Lebenszyklus nicht zu lösen sind. Vor allem ist die Auflösung von Datensilos

und Domain-übergreifendes Denken gefragt. Oft sind die Datenmodelle in den einzelnen Disziplinen unterschiedlich und bilden naturgemäß die Sprache des jeweiligen Bereichs ab. Digitale Zwillinge sollten deshalb erkennen, aus welchem Umfeld ein User kommt und seine Terminologie in andere Systeme übersetzen können.

Gut kuratierte Daten sind die Grundlage für den Erfolg

Allen ML Use Cases gemein ist, dass sie ein sauberes Fundament an Daten benötigen. Für alle Ansätze rund um ML und KI müssen die Daten in digitaler Form vorliegen, zugleich vollständig und nicht fehlerbehaftet sein. Hier ist es beispielsweise wichtig zu überprüfen, dass es keine Zeiträume gibt, in denen die Daten zufällig nicht gespeichert wurden.

Überall dort, wo es um Predictive Maintenance geht, braucht es Beispiele sozusagen für gute und schlechte Zeiten:

Sowohl Fehler als auch reibungsloser Betrieb sollten in den Daten vorkommen. Der Algorithmus kann schließlich nur das zuverlässig erkennen, was ihm vorher zuverlässig beigebracht wurde.

Immer dann, wenn Saisonalität eine Rolle spielt, sollten Daten eines ganzen Zyklus vorliegen, beispielsweise Sommer und Winter. Bei einem Gerät oder einer Maschine mit 24/7-Belüftungsmechanismus ist das irrelevant, aber in sehr vielen Kontexten ist es entscheidend, einen „Normalzustand“ jeweils für die warme und die kalte Jahreszeit zu definieren. Kein Wunder also, dass die Wettervorhersage in vielen KI-Anwendungen eine wichtige Rolle spielt. Ein gutes Datenfundament ist nicht nur die erste, sondern gleichzeitig die schwierigste Hürde, bevor Machine Learning in unterschiedlichen Kontexten wichtige Erkenntnisse aus den Daten ermöglicht. Die gute Nachricht: Danach wird die Umsetzung weiterer Vorhaben deutlich einfacher.

Jäger und Sammler: Alles im Data Lake aufbewahren

Die Daten erst einmal in einem Data Lake zu sammeln und keine Daten „wegzuwerfen“, ist durchaus eine sinnvolle Strategie. Sie geht jedoch nur auf, wenn genau hinterlegt ist, wie und wann genau die Daten aufgenommen wurden und nach welcher Methode. Der Prozess der Kuratierung und Aufbereitung der Daten bleibt nach wie vor niemandem erspart. In diesem Kontext kommt es insbesondere darauf an, Verantwortlichkeiten für die Daten festzulegen: Es braucht also einen Data Owner, Stichwort „Data Governance“. Um sehr viele Daten in Beziehung zu setzen, die unterschiedliche Formate haben und in verschiedenen großen Zeitintervallen erhoben werden, sollten sämtliche Rohdaten z. B. pro Millisekunde im Originalformat abgespeichert werden.

Wird ein Datenpunkt beispielsweise nur einmal pro Tag statt pro Sekunde gespeichert, dann lassen sich viele Fehler gar nicht aufspüren. Je höher die Granularität, desto besser. Das – nicht triviale – Zusammenbringen von Datenpunkten übernehmen die Algorithmen. Dazu muss jedoch zum einen klar sein, wie Sensoren, Geräte, Produkte oder Maschinen Daten liefern, und zum anderen, wie die Machine-Learning-Algorithmen die Daten aus dem Data Lake abgreifen. Vor allem müssen alle Daten mit ihrem Erfassungszeitpunkt gespeichert sein, um sie in exakten Timelines im Millisekundentakt synchronisieren zu können.

Viel Unklarheit bei datenbezogenen Prozessen

Laut der BARC-Studie „Leverage your Data“ im Auftrag einiger BI-Anbieter geben immerhin zwei Drittel der über 400 Teilnehmer an, viel Zeit damit zu verschwenden, immer wieder dieselben Fragen zu Daten zu stellen oder Arbeitsschritte doppelt auszuführen.

46 PROZENT

Prozent sind sich häufig nicht im Klaren darüber, wer welche Daten für welchen Zweck verwendet.

60 KNAPP UNTER PROZENT

der Unternehmen haben erkannt, dass sie mehr Informationen über ihre Daten brauchen und klare Verantwortlichkeiten schaffen müssen. Allerdings konnten die meisten diese Erkenntnisse noch nicht umsetzen.



Ohne Data Governance geht es nicht

Wenn Daten nicht ordentlich aufbereitet sind und die Data Governance fehlt, entsteht bei der Kuratierung ein erheblicher Aufwand für die Data Scientists. Es ist dann keine Seltenheit, dass 80 Prozent des Projektaufwands allein in die Datenvorbereitung fließen. Leider kann hier kein Algorithmus helfen, denn der Aufwand hängt von der Datenqualität und ordentlich annotierten Daten ab. Das ist in der Praxis nach wie vor eine der größten Herausforderungen. Data Governance ist auch kein technisches, sondern ein strategisch-kulturelles Thema: Die Grundlage bildet die Erkenntnis, dass Daten kein Nebenprodukt von Prozessen sind, sondern als Asset im Zentrum stehen, für das es Zuständigkeiten braucht. Das heißt konkret: Auch die Fachbereiche müssen lernen, sich um ihre Daten zu kümmern.

Gerade in den letzten zwei Jahren ist das Thema Datenkatalog immer populärer geworden. Denn User in Unternehmen haben oft Schwierigkeiten zu überblicken, welche Daten es im Unternehmen gibt. In fast allen Branchen herrschen noch Abteilungssilos vor. Datenkataloge zeigen deutlich, welche relevanten Daten aus anderen Bereichen oder aus externen Quellen nutzbar sind. Die Daten werden sozusagen auf einem zentralen Marktplatz virtuell gebündelt und beschrieben, der Zugriff gesteuert. Damit können zum Beispiel Anwender in der Entwicklung auf Produktionsdaten zugreifen.

Das spezifische Fach- und Prozesswissen vor Ort einbeziehen

Insbesondere im Produktionsumfeld kommt KI praktisch nie ohne intensive Einbeziehung des Fach-Know-hows der Mitarbeiter aus, die beispielsweise eine Anlage in- und auswendig kennen. Ein Data Scientist, der sich mit der Erstellung von Modellen befasst, muss die Prozesse ganz konkret und im Detail verstehen, deshalb ist Austausch so wichtig.

Dabei gilt es, die Domain-Experten als Partner ins Projektteam einzubinden und im agilen Entwicklungsprozess in Daily Meetings und Stand-ups eine engmaschige Kommunikation aufrecht zu erhalten. Es geht immer wieder um die Frage, was die Daten bedeuten und wie sie im Zusammenhang miteinander stehen. Oft scheitern Projekte in Produktion und Logistik, weil IT- und Daten-Experten nur anfänglich die Daten und das Wissen der Fachmitarbeiter abholen und dann erst nach Wochen wieder gemeinsam zusammenkommen. Das funktioniert nicht und hat sich in der Praxis schlicht als falscher Weg erwiesen.

Übrigens

Die Domain-Experten mit einzubeziehen, ist nur eine Seite der Medaille. Die Data Scientists, die die Modelle erstellen, spielen auch eine wichtige Rolle, sind aber sehr gefragte Experten. Sind sie nicht inhouse oder auf dem Arbeitsmarkt verfügbar, sollten Unternehmen für die Einführung von ML auf passende Cloud Enabler zugreifen. Doch nur wenige Dienstleister weltweit bringen das nötige Know-how-Level mit – Unternehmen sollten daher darauf achten, einen Partner zu wählen, der viel eigenes Know-how und Personal rund um KI aufgebaut hat.

So kommt KI schnell und effizient in die Praxis

Transparente Datenprozesse mit einem konkreten Use Case starten

Es kommt regelmässig vor, dass Unternehmen bereits eine konkrete Idee oder Vorstellung zu einem Problem haben, das mit KI lösbar sein könnte. Ein spezialisierter Cloud-Dienstleister hilft dabei, die Daten abzutasten, einen Data-Governance-Prozess und die nötigen Qualitätsmaßnahmen aufzusetzen. Ein spezifischer Use Case ist als Ausgangspunkt sinnvoll. Dennoch sollten die rund um diesen Case angesiedelten Maßnahmen, eine Data Journey zu definieren, praktisch immer als Blaupause für weitere Anwendungsszenarien dienen.

Auf Basis von AWS lässt sich im ersten Schritt zügig experimentieren und schnell, ohne weitere Investments, eine Hypothese austesten. In einem iterativen Prozess nähert man sich einem Minimal Viable Product (oder Modell) – wenn es nicht klappt, wird rasch ein anderer KI-Ansatz gewählt.

Plattform für eigene Datenprodukte

Das Ziel ist eine Plattform für Datenprodukte im Unternehmen. Jeder Schritt auf dem Weg trägt perspektivisch zu einem barrierefreien Zugang zu den Daten bei, sodass ein abteilungsübergreifender Zugriff möglich wird. AWS bietet eine gute Grundlage, um eine solche Plattform zu schaffen. Spezialisierte Dienstleister unterstützen auf Basis unterschiedlicher Konzepte und Templates dabei, das passende aus den vorhandenen Technologien auszuwählen und eine den jeweiligen Bedürfnissen entsprechende Plattform aufzubauen. Dafür gibt es einige typische Bausteine:



Der Cloud-Speicher

AWS S3 dient praktisch als Festplatte in der Cloud, wo Rohdaten gespeichert werden. Ein API Gateway sorgt z. B. für den Datenzugriff. Der Objektspeicher-Service lässt sich beliebig skalieren und eine Zugriffskontrolle ermöglicht die Einhaltung von Compliance-Vorgaben. Es gibt unterschiedliche Speicherklassen, sodass je nach Datenkategorie die günstigste Speicherform gewählt werden kann.

Unterschiedliche Datenquellen zusammenbringen

Für das Aufbereiten und Zusammenfügen der Daten kommt AWS Glue ins Spiel. Mit dem Serverlosen Datenintegrationsdienst werden Daten einfacher gefunden, extrahiert, aufbereitet und für Machine Learning kombiniert und integriert. Viele der klassischen ETL-Aufgaben können damit automatisiert werden. Zur Datenintegration zählt das Aufbereiten und Kombinieren verschiedenster Datenarten für die Analyse, Machine Learning und die Anwendungsentwicklung. Dazu gehören unter anderem das Anreichern, die Bereinigung und das Normalisieren von Daten, der Service hilft jedoch auch beim Laden und Organisieren der Daten beispielsweise in Data Lakes. Hinter diesen Aufgaben stehen viele unterschiedliche Systeme und Kompetenzen. Die Datenintegration kann über visuelle oder codebasierte Schnittstellen erfolgen.

Streaming-Daten in Echtzeit erfassen

Amazon Kinesis ist ein Service, mit dem sich Echtzeitdaten wie Video- und Audiodaten oder IoT-Telemetriedaten erfassen, puffern und für Maschinelles Lernen und Analytik nutzen lassen. Verarbeitung und Analyse sind dabei bereits möglich, bevor alle Daten vollständig erfasst wurden. Auswertungen sind oft schon nach wenigen Sekunden verfügbar. Die Verwaltung der Infrastruktur ist im Service enthalten. Es können beliebige Volumen von Streaming-Daten sowie Daten aus vielen Quellen auch mit besonders niedrigen Latenzen verarbeitet werden.

Bestandsdaten in die Cloud bringen

Um Bestandsdaten aus der On-Premises-Welt für einen schnelleren Zugriff einzubinden, eignen sich die AWS Database Migration Services. Während der Migration bleibt die Ursprungs-Datenbank vollständig betriebsbereit. So minimieren sich Ausfallzeiten für Anwendungen, die mit der Datenbank zusammenspielen. Daten lassen sich so kontinuierlich mit hoher Verfügbarkeit replizieren. Der Migrations-Service deckt fast alle gängigen Datenbanken ab, sowohl kommerzielle als auch Open-Source-Lösungen. Auch heterogene Migrationen zwischen verschiedenen Datenbankplattformen sind umsetzbar.

Barrierefreier Zugriff per Data Catalogue

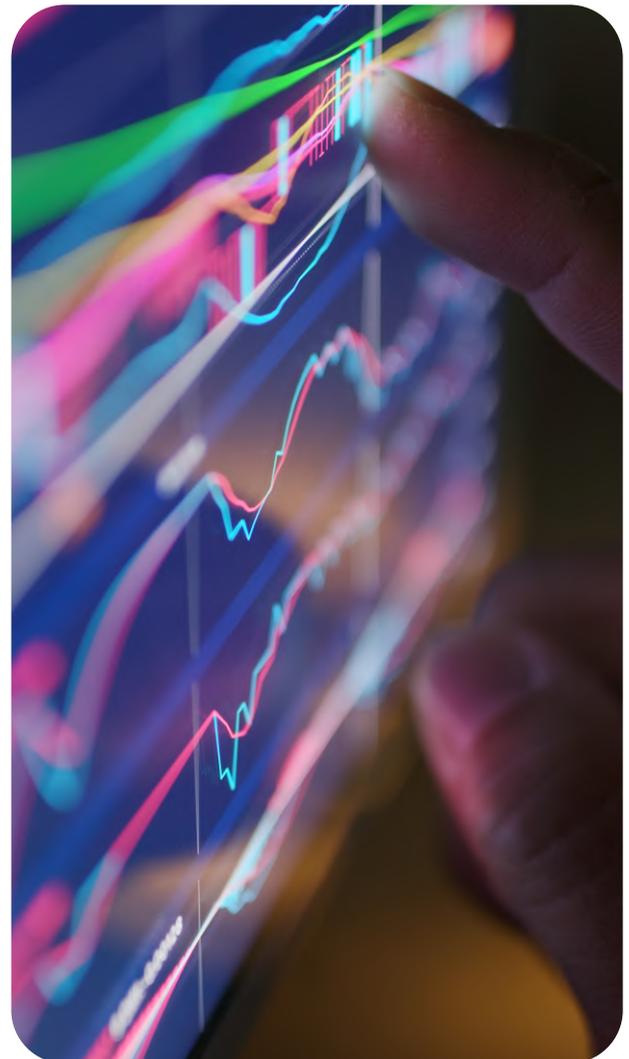
Um einen barrierefreien Zugriff für alle Mitarbeiter zu ermöglichen, ist ein zentraler Datenkatalog, oft auch als Datensupermarkt bezeichnet, das wichtigste Werkzeug. Ein solcher Data Catalogue ist ein wichtiger Teil von Amazon Glue. Es lassen sich allerdings auch andere Produkte von Drittanbietern nutzen, wie beispielsweise der Collibra Data Catalogue. In einem solchen Tool kann ein Mitarbeiter sehen, welche Daten aus den unterschiedlichen Bereichen wie Entwicklung, Produktion, Service, Einkauf/Beschaffung oder Qualitätsmanagement vorhanden sind, wer der Data Owner ist und wie oft die Daten abgetastet wurden.

Die Analytik-Ebene

AWS SageMaker dient in solchen Konzepten als Oberbau, in den sich Daten hineinziehen und analysieren lassen: Die Domäne der Data Scientists. Das Tool unterstützt mit einer visuellen Oberfläche bei einer schnellen Vorbereitung, Entwicklung und Bereitstellung von komplexen Machine-Learning-Modellen – und beschleunigt die einzelnen Schritte wie Kennzeichnung oder Annotation und Aufbereitung von Daten oder die Erkennung statistischer Verzerrungen. Data Scientists sind angesichts des Fachkräftemangels rar gesät. Gerade mittelständische Unternehmen stehen vor dem Problem, Spezialisten zu finden.

Deshalb ist es umso wichtiger, die Datenexperten mit wiederverwendbaren Algorithmen und Services von vielen Routinetätigkeiten zu entlasten.

In SageMaker sind die wesentlichen ML-Algorithmen vertreten, die fast alle Anwendungsfälle im industriellen Umfeld abdecken. Damit entfällt deren Integration für jeden Einzelfall. Im SageMaker Toolkit ist allerdings für speziellere Fälle auch der Zugriff auf freie KI-Frameworks wie TensorFlow, PyTorch oder MXNet möglich.



Die Industrie hat bei KI spezifische Bedarfe

Wie oben erwähnt, kommen bei der visuellen Qualitätskontrolle mittlerweile verstärkt Bilderkennungs-Anwendungen zum Einsatz, die beispielsweise die Oberfläche analysieren und bei Fehlern Alarm schlagen. Dazu müssen die Algorithmen zunächst trainiert werden, damit sie den Unterschied zwischen akzeptabel und inakzeptabel bzw. fehlerhaft erkennen. Das Training der Algorithmen gestaltet sich unterschiedlich komplex - je nach Lösung, die dafür eingesetzt wird. Im folgenden Case kam Amazon SageMaker zum Einsatz.

Praxisbeispiel 2: Automatisierte Qualitätskontrolle für Webprozesse

Auch in weniger stark digital automatisierten Produktionsumgebungen lässt sich mit visueller Qualitätsinspektion viel bewegen. So konnte ein mittelständischer Stoffhersteller seine Fehlerrate auf Basis von Amazon SageMaker deutlich reduzieren. Bevor die ML-Lösung eingeführt wurde, haben Mitarbeiter manuell per Stichprobe kontrolliert, ob die textilen Stoffe in Ordnung sind. Bei Fehlern musste das bis fünf Minuten vor und nach dem Fehler produzierte Material entsorgt werden. Sensordaten lagen zu Beginn nicht vor. Im ersten Schritt wurde daher eine Sensorik auf Basis von Raspberry Pi mit Kamera entwickelt.

In der Lernphase von ML-Projekten gilt es, möglichst viele Daten und Beispiele für korrekte und fehlerhafte Materialien zu generieren und dem Algorithmus zu Trainingszwecken vorzulegen. Dafür ist häufig eine entsprechende F&E-Entwicklungsvorarbeit nötig. Bei allen visuellen Ansätzen muss zudem vorher geklärt werden, ob sich ein Fehler überhaupt optisch feststellen lässt – ansonsten funktioniert ML hier nicht. In diesem Fall konnte ein Mensch die Qualität kontrollieren, indem die Stoffproben vor verschiedenartige Lichtquellen wie weißes oder blaues Licht gehalten wurden. Zunächst wurden also Bilder von Textilien mit dem eigenen Prototypen aufgenommen und manuell über 200 Fälle markiert.

Low Code hilft beim KI-Einstieg

Die oben beschriebene Vorgehensweise beim Stoffhersteller wurde zu einem Zeitpunkt eingesetzt, als es dazu kaum Alternativen gab. Auch heute sind viele Unternehmen aufgeschlossen und wollen sich mit Machine Learning auseinandersetzen, doch es fehlt weiterhin an Data Scientists.

Das haben Anbieter wie AWS erkannt. Seit kurzem gibt es daher Machine Learning in Form von "LowCode/NoCode" Ansätzen, die verschiedene industrielle Anwendungsfälle abbilden. Damit lassen sich eigene Anwendungen noch schneller umsetzen. So erklärt sich letztlich auch der Trend hin zu einfacher bedienbaren Lösungen. Anbieter wie AWS haben mittlerweile Services im Programm, in denen die Praxisexpertise aus vielen Projekten eingeflossen ist. Das ist zum Beispiel rund um die Objekterkennung der Fall.

Bild- und Videodatenverarbeitung: Lookout for Vision

Amazon Lookout for Vision ist eine No/Low-code Lösung für Anomalie-Erkennung auf Basis von Computer Vision in Bild- und Videodaten. Der ML-Service hilft bei der Erkennung und Vermeidung von Fehlern und Problemen in der Produktherstellung. Insbesondere Qualitätsmanagement-Prozesse können so deutlich beschleunigt und bisher manuelle Inspektionsabläufe automatisiert werden. Neben Fehlern in Materialien oder Oberflächen lassen sich auch fehlende Komponenten zum Beispiel in Baugruppen erkennen.

Auf einer dafür ausgelegten GUI oder eine API werden zunächst Bilder hochgeladen. Der Nutzer kann dann angeben, welche der Bilder gute oder schlechte Qualität zeigen. Das Modell wird anschließend mit diesem Input automatisch trainiert. Die ansonsten aufwendige Entscheidung, welche Parameter und welche Algorithmen am besten geeignet sind, übernimmt der Service. Dazu gehören auch die Einbindung von Data Pipelines und die Transformation der Daten. Das ist zwar etwas teurer - letztlich lässt sich so allerdings oft der Einsatz eines Data Scientists vermeiden und der Experte bleibt frei für komplexere Aufgaben. Wartung und Upgrades werden automatisch abgedeckt. Wenn neue Versionen entwickelt werden, erfolgt eine nahtlose Integration. Mit einigen Services von Lookout for Vision ist der Start bereits ab 30 Bildern möglich.

Amazon Lookout for Equipment

Lookout for Equipment fokussiert die Verarbeitung von Sensordaten in industriellen IoT-Szenarien. Dabei liegt ein Schwerpunkt auf der Erfassung von Zeitreihendaten, wie sie häufig bei Motoren oder Turbinen relevant sind. Es lassen sich bis zu 300 Sensoren einbinden, die Lösung spielt selbst bis zu 28.000 mögliche Algorithmus-Kombinationen durch, um festzustellen, wie sich das genaueste Ergebnis erzielen lässt. Typische Sensorwerte sind Umdrehungen, Druck, Temperatur, Feuchtigkeit, Durchfluss oder Spannung. Infrage kommen fast alle Sensortypen. So bleibt viel Spielraum, um mittels Retrofitting neue Werte abzugreifen, die vorher nicht vorhanden waren. Zugleich wird Sensorik immer günstiger, energieeffizienter und leichter nutzbar: Beispielsweise gibt es zunehmend Sensoren, die sich auf Maschinen aufkleben lassen, um Parameter wie Vibration oder Hitzeentwicklung zu messen. Der ML-Service nimmt vor allem die Themen vorausschauende Wartung, Condition Monitoring und Anomalie-Erkennung in den Blick, um bei abweichendem Verhalten ungeplante Ausfallzeiten zu vermeiden.

Spezial-Hardware per Cloud für Industrieszenarien nutzen

Die Konzepte umfassen auch die Hardware-Anbindung: Das ist vor allem deshalb relevant, weil im rechenintensiven KI-Umfeld die enge Verzahnung von Hard- und Software essenziell ist: Das wird beispielsweise im Umfeld der Bild- und Video-Stream-Erkennung deutlich, wo spezielle GPU (Graphic Processing Units) die Nase vorn haben, bei denen Algorithmen praktisch in Hardware gegossen sind. Gleichzeitig liegt hier auch der Grund, warum Cloud Computing der richtige Weg ist: Oft sind die Hardware-Bedarfe aufwendig und exotisch, teilweise werden vor allem in der Trainingsphase massive Rechenkapazitäten benötigt. Eine Beschaffung dieser Bedarfe On-Premise ist deutlich zu teuer und aufwendig – zudem ist hier das experimentelle Herantasten an die optimale Vorgehensweise und den am besten passenden Algorithmus so nicht möglich.

Entscheidendes Argument für die Cloud sind jedoch vor allem Skalierung und Industrialisierung. Zwar wurden in der Vergangenheit einige Lösungen On-Premise an einer bestimmten Anlage oder Fertigungslinie entwickelt. Die Anwendungsfälle hatten jedoch fast immer F&E-Charakter und waren nicht produktionsreif. Um Machine Learning in die Breite zu bringen, ist ein anderes Fundament notwendig.

Die Herausforderungen in der Produktion ähneln sich

Unternehmen stoßen im industriellen Umfeld immer wieder auf gleichartige Probleme. Das Rad muss daher nicht immer neu erfunden werden. Typischerweise ähneln sich vor allem die Herausforderungen im Fabrikumfeld, wo in der Edge die Operations Technology (OT) mit eigenen Anforderungen, Netzwerken und Protokollen regiert. Für die Integration mit der IT stehen AWS-Services zur Verfügung, mit denen beispielsweise Industrie-PC's eingebunden werden können. In der Edge ist üblicherweise die Latenz niedriger, es können aber nicht ständig Millionen Bilder für die spätere Analyse in die Cloud geladen werden: Stattdessen muss die Auswertung in leistungsstarken Edge-Komponenten bereits vor Ort stattfinden. Auch die Datensicherheit steht im Vordergrund: Mit der Öffnung entstehen sonst Einfallstore in die vormals stark abgeschirmten Fabrikumgebungen mit immer noch vielen proprietären Lösungen. Um die ausgewählten Daten dann in den Data Lake in der Cloud zu übertragen, ist also die richtige Connectivity nötig, beispielsweise unterstützt AWS hier Formate wie MQTT.



Die Auswahl der richtigen Parameter ist entscheidend

Um bei Predictive Maintenance wirklich gute Ergebnisse zu erreichen, kommt es auf die Auswahl der richtigen technischen Parameter unter anderem aus den Steuerungen an. Oft gilt es, aus tausenden Werten all diejenigen zu identifizieren, die an einem Ausfall beteiligt sein könnten und sie auf die Parameter herunterzubrechen, deren Aussagekraft besonders hoch ist. Manche Daten haben nur eine unterschwellige Bedeutung, sind aber äußerst wichtig, um eine möglichst frühzeitige Prognose zu ermöglichen. Vor allem müssen alle Daten miteinander korreliert werden, um auch unwahrscheinliche Zusammenhänge aufzuspüren: Ein anderer Lichteinfall, ein Spinnennetz, eine offene Tür oder andere Luftbewegungen.



Fazit

Im Umfeld von Machine Learning ist ein sehr großes Spielfeld zu navigieren. Auch bei den fortgeschrittenen Services, die mittlerweile sehr viel inhärentes Know-how mitbringen, sollte jedoch mit einem erfahrenen Partner zusammengearbeitet werden, um die Bausteine optimal zusammensetzen. Um es lapidar zu sagen: Auch mit Lego lassen sich sehr hässliche Schlösser und dysfunktionale Todessterne bauen. Der Nutzen von ML ist aber kaum zu unterschätzen. Mittelfristig lässt sich die Effizienz der Produktion durch den Einsatz von ML steigern, während Kosten gesenkt werden können. Und oft wirkt sich ML über das eigentliche Einsatzszenario hinaus aus, denn die Algorithmen decken meist weitere, bisher unbekannte Probleme und Fehlerursachen auf.



Über AllCloud

AllCloud ist ein weltweit aktiver Anbieter von Professional Services und Managed Services, der Unternehmen mit Tools für das Cloud Enablement und die Cloud Transformation unterstützt. Durch eine einzigartige Kombination von Expertise und Agilität beschleunigt AllCloud das Potenzial von Cloud-Innovationen und hilft Unternehmen, den Wert der Cloud-Technologie voll auszuschöpfen. Als AWS Premier Consulting Partner unterstützt AllCloud Kunden bei dem Aufbau eines neuen Betriebsmodells, mit dem sie die Vorteile von AWS effizient und sicher nutzen. AllCloud greift auf ein leistungsstarkes Ökosystem von Technologiepartnern, bewährten Methoden und gut dokumentierten Best Practices zurück. AllCloud unterstützt seine Kunden dabei, operative Exzellenz mit der Cloud zu erreichen, in einer sicheren Umgebung und bei jedem Meilenstein auf dem Weg zu einem Unternehmen mit einer Cloud-Strategie.

Mit über 12 Jahren Erfahrung und einem Portfolio mit Tausenden von erfolgreichen Cloud Deployments und zahlreichen Zertifizierungen bedient AllCloud Kunden auf der ganzen Welt. AllCloud hat Niederlassungen in Israel, Europa und Nordamerika.

 <https://allcloud.io>  @_AllCloud

