

KI hilft bei der Ursachenanalyse

Co-Innovationsprojekt von Trumpf und Xplain Data

„KI unterstützt uns bei der Identifikation von Wirkzusammenhängen in komplexen Daten“, sagt Dr.-Ing. Mathias Kammüller, Chief Digital Officer und Trumpf-Vorstandsmitglied. „Die Kunst liegt darin, die KI mit dem vorhandenen Domänenwissen zu kombinieren.“ Dieser Herausforderung stellen sich die Verantwortlichen bei Trumpf in einem aktuellen Projekt.

Emanuel Sideras, Michael Haft



Eine wesentliche Aufgabe im Qualitätsmanagement ist die Überwachung von Kennzahlen. Reißt eine Kennzahl aus, stellt sich die Frage nach dem Warum, und die Ursachensuche beginnt. Der Ursachenanalyseprozess lässt sich abstrakt darstellen (Bild 1). Folgende Punkte sind durch ein Wechselspiel zwischen Sachlogik und Datenanalyse zu klären:

1. Identifikation: Welche Ursachen führen zu der Wirkung?
2. Quantifizierung: Welcher Anteil der Wirkung wird durch welche Ursache erklärt?
3. Unbekannter Anteil: Wie groß ist der unerklärte Anteil und wie groß ist die Unsicherheit in den Aussagen?

Systematische Herausforderungen bei der Suche nach der Ursache

Herausforderung 1: „Was ist die Ursache für ein Problem?“

Diese Frage wird gerne so gestellt. Aber gibt es „die“ Ursache? Die 5-Why-Methode ver-

anschaulicht die Problematik an einem einfachen Beispiel. Beginnend mit dem Fehlerbild „Fahrzeug startet nicht“ kann man die Warum-Frage wiederholt stellen, um tiefer liegenden Ursachen auf die Spur zu kommen (Bild 2). Es gibt also nicht „die eine“ Ursache, sondern eine ganze Kette von Ursachen. Welche der Ursachenebenen möchte man als Ergebnis in der Analyse sehen? Für einen Kfz-Werkstattmeister, der das Auto reparieren möchte, ist die Ursache aus Ebene 1 kein brauchbares Ergebnis, für ihn ist die Ebene 3 relevant. Wenn er weiß, dass der Keilriemen gerissen ist, kann er ihn ersetzen. Für einen Zuverlässigkeitsingenieur dagegen, der die Wartungsintervalle optimieren möchte, ist die Ebene 4 relevant.

Ein Algorithmus kann vor der Analyse nicht wissen, welche Ursachenebene relevant ist, **da** die relevanten Ursachenebenen für ein und dieselbe Wirkung von Fragestellung zu Fragestellung variieren.

Fazit: Es wird ein Experte mit Domänenwissen benötigt, um nach einer »»




Bild 1. Der Ursachenanalyseprozess. Quelle: Trumpf © Hanser

ersten Analyse die nächste Warum-Frage zu stellen und zu der für ihn relevanten Ursachenebene vorzustoßen.

In jedem Einzelfall gibt es eine Kette von Ereignissen und verschiedene Ursachenebenen. In der statistischen Analyse vieler Fälle müssen wir von einem Netzwerk von Ursache-Wirkungs-Zusammenhängen sprechen, in dem es eine Fülle von Korrelationen gibt.

zu interpretieren (wie quasi alle „Big Data“).

In solchen Daten mag es sogenannte „Confounder“ geben, die zu beobachtenden Korrelationen zwischen zwei Ereignissen führen, obwohl es keinen ursächlichen Zusammenhang zwischen diesen beiden gibt (siehe Bild 3).

Verfahren aus dem Bereich der Künstlichen Intelligenz können sehr komplexe und umfangreiche Daten nach solchen

Trumpf hat sich zu einem Co-Innovationsprojekt mit dem Startup Xplain Data entschieden, da deren Technologie die obigen Herausforderungen adressiert. Es wurde eine Proof of Concept gestartet, in dem die ursprünglich für den Pharmabereich konzipierten Methoden, auf die Anforderungen von Trumpf angepasst und auf aktuelle Fragestellungen angewandt wurden.

KI hilft potenzielle Ursachen zu identifizieren und zu quantifizieren

Kausale Beziehungen lassen sich also anhand von Beobachtungsdaten nicht beweisen. Wie können uns Verfahren der KI trotzdem von Nutzen sein?

Nutzen 1: Unübersichtlich viele Korrelationen werden zu wenigen Hypothesen für potenzielle Kausalitäten.

Bei der klassischen Ursachenanalyse geht




Bild 2. Die 5-Why Methode veranschaulicht die Problematik der Ursachensuche. Quelle: Trumpf © Hanser

Herausforderung 2: Korrelation bedeutet nicht zwangsläufig Kausalität

Der Beweis eines kausalen Zusammenhangs bedarf eines Experiments. So führt die Pharma-Industrie zum Beispiel teure randomisierte Studien durch, um die Wirksamkeit einer Therapie nachzuweisen. Daten, die im realen Betrieb einer Maschine gesammelt werden, sind keine solchen experimentell kontrollierten Daten, sondern sind als sogenannte „Beobachtungsdaten“

Confoundern analysieren. Nur wenn sich für einen beobachteten Zusammenhang keine Erklärung über einen Confounder findet, entsteht der Verdacht eines kausalen Zusammenhangs. Was aber, wenn die Confounder nicht in den Daten enthalten sind?

Fazit: Es wird ein Experte mit Domänenwissen benötigt, um über die Sachlogik zu beurteilen, ob eine identifizierte Korrelation auch ursächlich ist.

Es gibt also mindestens zwei Gründe, warum Ursachenanalyse eine Herausforderung ist, und ein iterativer Prozess in enger Involvement der Domänen-Experten notwendig ist. Weder nur durch Datenanalyse noch mit Fachwissen allein lassen sich die drei Ziele aus der Einleitung erreichen.

Gute Verfahren zur Ursachenanalyse sollten sowohl komplexe Datenstrukturen auf Confounder analysieren können wie auch die Einbindung der Domänen-Experten unterstützen.

man von Hypothesen für Ursachen aus, und versucht diese zu verifizieren oder falsifizieren. Hierzu formuliert ein Experte einen Verdacht für eine potenzielle Ursache.

Die unvoreingenommene Suche der KI-Verfahren in den Daten ergänzt dabei die sachlogisch erwarteten Faktoren. Nicht selten kommt es in einem Abgleich der beiden Herangehensweisen zu Überraschungen. Manche Faktoren können sich als Ursachen herausstellen, die der Experte nicht in Verdacht hatte. Umgekehrt können sich vom Experten erwartete Faktoren als über einen Confounder erklärbar herausstellen – und damit bestenfalls als indirekte Ursachen.

Nutzen 2: Der Domänen-Experte erhält intuitiv verstehbare Ergebnisse als Basis für den iterativen Analyseprozess.

Für ein solches Zusammenspiel von Experte und Künstlicher Intelligenz ist es notwendig, dass Analyse-Ergebnisse bzw. Parame-





Bild 3. Identifizierte Korrelation Quelle: Trumpf © Hanser



Beispiel 1: Feldausfälle korrelieren mit hohen Messwerten von Prüfmerkmal (End-of-Line Prüfung). Quelle:

Trumpf © Hanser

oder „mit Kanonen auf Spatzen“ geschossen wird.

Beispiele für Ergebnisse aus dem Proof of Concept

In einem POC wurden die Ursachen für verschiedene Zielgrößen gesucht. Die Ursachen wurden hauptsächlich in zwei Arten von Daten gesucht (Bild 4):

1. Inhärente Produkteigenschaften bei Auslieferung (zum Beispiel Hardware-/Software-Serienstand, Materialnummern, Auslieferland, Prüfmerkmalswerte bei der EOL-Prüfung et cetera)
2. Der Zielgröße vorangegangene Ereignisse und Signale im Feld (zum Beispiel maschinell aufgezeichnete Ereignisse im Betrieb, Betriebsstunden et cetera)

Es folgen verschiedene Beispiele von Analyseergebnissen, die hier abstrakt beschrieben werden.


Beispiel 1: Feldausfälle korrelieren mit hohen Messwerten von Prüfmerkmal (End-of-Line Prüfung)

Produkte mit hohen Messwerten weisen eine signifikant höhere Ausfallrate auf als Produkte mit niedrigen Messwerten. Diese Korrelation konnte nicht über einen Confounder erklärt werden. Aus Sicht der Daten ist also von einem potentiell ursächlichen Zusammenhang auszugehen.

Auf Basis dieser Information kann die Produktion nun auch eine sachlogische Abklärung der Ursächlichkeit vornehmen und abwägen eine Akzeptanzgrenze einzuführen (zum Beispiel bei 80, siehe Beispiel 1). Dadurch entsteht Nacharbeit in der Produktion, es wird jedoch die Ausfallwahrscheinlichkeit im Feld reduziert.

Beispiel 2: Feldausfälle korrelieren mit verwendetem Justier- und Messsystem.

Quelle: Trumpf © Hanser



ter des Modells intuitiv verstehbar sind. Hierzu kommen sogenannte ICI-Modelle zum Einsatz (Independence of Causal Contributions).

Ein Gesamteffekt wird damit in unabhängige Beiträge zerlegt, so dass Faktoren unabhängig voneinander interpretiert und vom Experten bewertet werden können – ein wesentliches Element in dem Zusammenspiel von Experte und Algorithmus. Gleichzeitig unterstützen interaktive Oberflächen einen Prozess von Frage und Folgefrage (5Ws).

Nutzen 3: Quantifizierung des Effektes von Ursachen


Die Zerlegung in unabhängige Beiträge bringt auch den Vorteil einer quantitativen Bewertung einzelner Faktoren mit sich und die Information, ob dieser überhaupt statistisch signifikant ist (p-Wert).

Schlussendlich ist es das Ziel einer Ursachenanalyse, in die Entwicklung, die Produktion oder den Betrieb einer Maschine so zu intervenieren, dass zukünftige Fehlerursachen vermieden werden. Erst wenn ein Faktor quantifiziert ist, kann auch bewertet werden, ob eine Maßnahme adäquat ist,


Beispiel 2: Feldausfälle korrelieren mit verwendetem Justier- und Messsystem

Produkte, die mit dem Justier- und Messsystem Nr. 24 eingestellt wurden, weisen eine signifikant höhere Ausfallrate auf, als der Durchschnitt der anderen. Laut Modellrechnung lassen sich 7 von 10 Fehlern ausschließlich durch den Faktor „Messsystem Nr. 24,“ erklären (das heißt, es waren in den Daten keine anderen Erklärungen/Confounder für diese Auffälligkeit zu finden).

In einer detaillierten Betrachtung der 10 Fehler durch den Fachbereich ließ sich bei 7 von 10 Fehlern ein ursächlicher Zusammenhang feststellen und somit die »»



Beispiel 3. Zeitlicher Verlauf der Ereignisse pro Maschine und Analyseergebnisse. Quelle: Trumpf © Hanser



Beispiel 4. Modellgüte (AUC) und die Prognosen in Abhängigkeit der berechneten Ausfallwahrscheinlichkeit. Quelle: Trumpf © Hanser

Modellrechnung bestätigen (Beispiel 2).

Beispiel 3: Feldausfälle korrelieren mit vorangegangenen Reparaturereignissen

Das Bild (Beispiel 3) zeigt beim Kunden installierte Maschinen übereinander aufgetragen (Y-Achse) und den zeitlichen Verlauf ihrer Fehlerereignisse (X-Achse). Es soll das Fehlerereignis Fx erklärt werden (Tausch einer Baugruppe), das insgesamt 75 Mal stattgefunden hat.

Eine Hypothese lautet, dass ein bestimmtes zeitlich vorgelagertes Reparaturereignis H1 zu dem Tausch der Baugruppen führt. Aus sachlogischen Gründen ist es jedoch zu erwarten, dass das Reparaturereignis H1 nicht jedes Mal zum Tausch der Baugruppe führt (Beispiel 3).

Bei 13 von 75 (17 Prozent) der getauschten Baugruppen hat das Reparaturereignis H1 zuvor stattgefunden. Wie viele getauschte Baugruppen können auf das vorangehende Reparaturereignis H1 zurückgeführt werden?

Die Schwierigkeit bei der Beantwortung dieser Frage: Vor dem Tausch der Baugruppen hat nicht nur das Reparaturereignis H1 stattgefunden, sondern auch diverse andere Reparaturereignisse, die ebenfalls einen Einfluss haben könnten. Darüber hinaus gibt es auch die inhärenten Produkteigenschaften bei Auslieferung, die auch als erklärende Faktoren in Frage kommen. Bei einer typischen Analyse kommen wir auf über 400.000 Faktoren, die bei der Modellbildung als potenzielle Ursachen geprüft werden. Erst wenn sich der Einfluss eines Faktors sich nicht über einen anderen Faktor „wegklären“ lässt, wird er in das Erklärungsmodell aufgenommen und quantifiziert.

Für unser Beispiel hat das Modell das Reparaturereignis H1 als signifikant bewertet und mit einem Effekt von 9 quantifiziert. Das heißt: Für 9 der 75 getauschten Baugruppen darf das vorangehende Ereignis H1 als die Ursache für den Tausch angenommen werden.

Der Fachbereich hat die Reparaturberichte für die 13 getauschten Baugruppen studiert und aus den Inhalten rückgeschlossen, dass bei 9 von 13 getauschten Baugruppen das vorgelagerte Reparaturereignis als ursächlich gesehen werden kann und somit die Identifizierung des Faktors H1 wie auch seine Quantifizierung validiert (Beispiel 3, Erklärende Faktoren).

Beispiel 4: Vorhersagen für einzelne Produkte

Liegt ein gutes Erklärungsmodell vor, kann es genutzt werden, um die Ausfallwahrscheinlichkeit für noch nicht ausgefallene Produkte vorherzusagen. Liegt diese über einem definierten Grenzwert (zum Beispiel 70 Prozent), kann ein Frühwarnsignal an den Service oder an den Kunden erfolgen, und entsprechende Maßnahmen können eingeleitet werden.

Die Bilder zeigen die Modellgüte (AUC) und die Prognosen in Abhängigkeit der berechneten Ausfallwahrscheinlichkeit (Bei-

spiel 4). Wenn für alle Maschinen mit einer berechneten Ausfallwahrscheinlichkeit von > 70 % ein Alarm ausgelöst wird, gibt es 10 Alarme – davon nur einmal zu Unrecht. Bei insgesamt 45 Fehlerereignissen hätte also in 9 Fällen eine frühzeitige Intervention stattfinden können.

Fazit: Zu Beginn des Projektes waren die Bedenken groß, da wichtige Daten bisher noch nicht erhoben werden, und da




Bild 4. Verwendetes Datenmodell im Proof of Concept. Quelle: Trumpf © Hanser

vorhandene Daten aus einem manuellen Erfassungsprozess mit fragwürdiger Datenqualität stammen. Die Ergebnisse des POCs waren jedoch weitaus besser als erwartet. So wurde beschlossen, diese erfolgreiche Methodik als Standard in die QM-Analyseprozesse zu implementieren – so Dr. Volker Hettich, Leitung zentrales Qualitätsmanagement.

Operationalisierung und die Stimme der Enabler

Die Implementierung der KI-Methodik war nur durch die intensive crossfunktionale Zusammenarbeit vieler Enabler wie IT, Informationssicherheit, Entwicklung, Feldanalyse, Produktion und viele weitere beteiligte Abteilungen möglich.

Der Betrieb findet auf zwei Arten statt:

1. Manuell: Über eine interaktive Oberfläche können berechtigte User individuelle Ursachenanalysen konfigurieren, durchführen und diese als Vorlage abspeichern.
2. Automatisiert: Auf Basis tagesaktueller Daten werden für verschiedene Use Cases nachts standardisierte Analysen durchgeführt, deren Ergebnisse den Fachbereichen morgens zur Verfügung gestellt werden.

Folgende Use Cases werden abgedeckt:

- Identifikation erklärender Faktoren für den Unterschied zwischen Produkten mit hohen vs. Produkten mit niedrigen Ausfallraten (zur Unterstützung der Feldanalyse und Entwicklung)
- Identifikation erklärender Faktoren für den Unterschied zwischen Produkten mit hohen vs. Produkten mit niedrigen Qualitätskosten (zur Unterstützung des Qualitätsmanagements)
- Auflistung von Prüfmerkmalen sowie Justier- und Messsystemen, die als erklärende Faktoren zu Fehlerbildern im Feld identifiziert werden (zur Unterstützung der Produktionswerke)
- Auflistung einzelner Produkte mit einer hohen Ausfallwahrscheinlichkeit zu

bestimmten Fehlerbildern (zur Unterstützung des Condition-Monitorings)

Durch die KI-Methodik hat Trumpf nun ein Werkzeug zur Verfügung, um bei Ursachenanalysen nicht nur einzelne Tabellen, sondern automatisiert ganze relationale Datenmodelle zu durchsuchen. So wurde eine skalierbare Methodik zur Generierung von Systemwissen entwickelt. ■

Stimmen zum Projekt

Martin Barthau, IT / Data Management Platforms: „Basis für dieses Projekt war die vorgelagerte firmenübergreifende Zusammenführung unterschiedlichster Datenquellen auf der „Data Integration Plattform“. Darüber ist es möglich den Fachbereichen Daten gebündelt und kontrolliert zur Verfügung zu stellen.“

Dr. Zaigham Faraz Siddiqui, Entwicklung / EcoSystem Data & AI: „Für das Zusammenspiel der verschiedenen Systeme war die Vernetzung unterschiedlicher Plattformen (Azure, R-Studio Connect) notwendig. Für

die parallelisierte Berechnung der Modelle werden 16 Cores / 60 GB RAM verwendet, die zeitweise zu 100% ausgelastet sind.“

Erik Brannath, Zentrales Qualitätsmanagement / Q-Methods & Analytics: „Die aus Einzelquellen zusammengeführten Daten erlauben es, angereicherte Datenmodelle zu erstellen. Voraussetzung dafür ist, dass die Logiken und Konventionen der dahinterliegenden Prozesse verstanden werden. Dies wiederum erfordert einen engen Austausch mit den Daten- und Prozessverantwortlichen.“

INFORMATION & SERVICE

AUTOREN

Emanuel Sideras ist Six Sigma Master Black Belt im zentralen Qualitätsmanagement bei der Firma TRUMPF SE + Co. KG.
Dr. Michael Haft ist CEO der Firma Xplain Data GmbH.

UNTERNEHMEN

Die – immer noch in Familienhand befindliche – Trumpf Gruppe mit Stammsitz in Ditzingen wurde 1923 als mechanische Werkstatt gegründet und hat sich zum Technologie- und Marktführer bei Werkzeugmaschinen für die flexible Blechbearbeitung und bei industriellen Lasern entwickelt. So liefert der Laserspezialist beispielsweise die EUV-Laser zur Belichtung der neuesten Chip-Generation für die aktuellen Apple-Geräte. Im Geschäftsjahr 2020/21 erwirtschaftete das Unternehmen mit 14.767 Mitarbeitern und 80 weltweiten Tochtergesellschaften einen Umsatz von 3,5 Millionen Euro.

KONTAKT

TRUMPF SE & Co. KG
emanuel.sideras@trumpf.com
T +49 7156 303-31487
www.trumpf.com