

Business News

DOAG Zeitschrift für die Anwender von Oracle Business- und BI-Lösungen



Big Data und Internet of Things

Vorhersagen

Predictive Analytics
in der Praxis

Seite 5

Industrie 4.0

Apps auf dem Shopfloor
einsetzen

Seite 24

Best Practice

Digitale Transformation
in Unternehmen

Seite 33

Save the Date

2017
DOAG

Konferenz + Ausstellung
21. - 24. November in Nürnberg



2017.doag.org



Peter Welker
DOAG-Themenverantwortlicher
für Big Data

Liebe Leserinnen und Leser,
auf der DOAG 2016 Konferenz moderierte ich zusammen mit Björn Ständer von Oracle und Rolf Scheuch, Leiter der DOAG BI Community, eine Reihe von Meinungsforen zum Thema „Big Data und Business Intelligence“. Wir durften dabei abwechselnd in eine von zwei Rollen schlüpfen: Der erfahrene, über Dekaden IT-gestählte „Traditionalist“ war davon überzeugt, alle neuen Anforderungen mit etablierten relationalen Datenbanken, Datenintegrations- und Reporting-Werkzeugen sowie einer straff organisierten, zentralen IT lösen zu können.

Auf der anderen Seite stand der „Innovator“, jung, hip, mit neuen Ideen und bestens vertraut mit Big-Data- und IoT-Technologien (sich großteils überschneidend). Für ihn stand außer Frage, dass neben neuen Werkzeugen wie NoSQL-Datenbanken, Hadoop und Spark nur eine schnellere, dezentrale, Public-Cloud-basierte, durch den Fachbereich gesteuerte und stark projektorientierte Arbeitsweise geeignet ist, unsere Daten zu bewältigen und ihnen neue und wesentliche Informationen zu entlocken.

Obwohl der Innovator offenbar gute Argumente hatte – weniger Kosten, schnellere Ergebnisse, mehr Nutzen, bessere Skalierbarkeit – war es erstaunlicherweise wesentlich einfacher, den Traditionalisten zu spielen. Schlimmer noch: Es machte auch viel mehr Spaß! Eine dezentrale IT ließ sich publikumswirksam als „Schatten-IT“ verunglimpfen und mangels langjähriger Projekte waren die Behauptungen des Innovators nicht nachweisbar. Wirkungstreffer gelangen zudem mit „Datenqualität“ und dem selbstkritiklosen „das haben wir vor 25 Jahren schon einmal gelöst“.

Ein besonderer Zweifel aber blieb allgegenwärtig: „Wir sind nicht Google oder Facebook. Wir haben überhaupt keine Use Cases, für die man neue Lösungen braucht!“ Ist das so? Was macht diese Daten-Giganten denn so erfolgreich? Sicher der passende Zeitpunkt (die Konkurrenz war zu langsam oder zu kompliziert), die passende Idee (schnelle Suchmaschine/einfaches Identitätsmanagement) und eine passende Firmenkultur (wie kein Kästchendenken bei Daten). Dazu die Erkenntnis, dass man seine Daten nicht wegwirft, weil sie irgendwann wichtig sein könnten und Speicherplatz relativ günstig ist.

In den Branchen Energie, Telekommunikation und Industrie gibt es maschinell erzeugte Daten in enormem Umfang, die auch unter strengen Datenschutz-Bestimmungen noch nicht ansatzweise erschlossen sind und zusammen mit externen Informationen (geografische Daten, Social Media, Bewegungsdaten) ein großes Potenzial bieten.

Ihr

Impressum

DOAG Business News wird von der DOAG Deutsche ORACLE-Anwendergruppe e.V. (Tempelhofer Weg 64, 12347 Berlin, www.doag.org), herausgegeben. Es ist das User-Magazin rund um die Applikations-Produkte der Oracle Corp., USA, im Raum Deutschland, Österreich und Schweiz. Es ist unabhängig von Oracle und vertritt weder direkt noch indirekt deren wirtschaftliche Interessen. Vielmehr vertritt es die Interessen der Anwender an den Themen rund um die ORACLE-Produkte, fördert den Wissensaustausch zwischen den Lesern und informiert über neue Produkte und Technologien.

DOAG Business News wird verlegt von der DOAG Dienstleistungen GmbH, Tempelhofer Weg 64, 12347 Berlin, Deutschland, gesetzlich vertreten durch den Geschäftsführer Fried Saacke, deren Unternehmensgegenstand Vereinsmanagement, Veranstaltungsorganisation und Publishing ist.

Die DOAG Deutsche Oracle-Anwendergruppe e.V. hält 100 Prozent der Stammeinlage der DOAG Dienstleistungen GmbH. Die DOAG Deutsche Oracle-Anwendergruppe e.V. wird gesetzlich durch den Vorstand vertreten; Vorsitzender: Stefan Kinnen. Die DOAG Deutsche Oracle-Anwendergruppe e.V. informiert kompetent über alle Oracle-Themen, setzt sich für die Interessen der Mitglieder ein und führen einen konstruktiv-kritischen Dialog mit Oracle.

Redaktion:

Sitz: DOAG Dienstleistungen GmbH
(Anschrift s.o.)

Chefredakteur (ViSdP): Wolfgang Taschner

Kontakt: redaktion@doag.org

Weitere Redakteure (in alphabetischer Reihenfolge): Mylène Diacquenod, Marina Fischer, Sebastian Höing, Michael Klose, Fried Saacke, Dr. Frank Schönthaler

Druck:

adame Advertising and Media GmbH, Berlin,
www.adame.de

Fotonachweis:

Titel: © theromb/123RF

Foto S. 5: © Vitaliy Vodolazskyy/123RF

Foto S. 9: © everythingpossible/123RF

Foto S. 10: © Dmitry Kalabin/123RF

Foto S. 11: © rawpixel/123RF

Foto S. 13: © Claudia Mora/123RF

Foto S. 18: © bowie15/123RF

Foto S. 24: © aimage/123RF

Foto S. 27: © whitehoune/123RF

Foto S. 33: © Edhar Yuralaits/123RF

Foto S. 38: © Marco Lachmann/123RF

Titel, Gestaltung und Satz:

Caroline Sengpiel,

DOAG Dienstleistungen GmbH (Anschrift s.o.)

Anzeigen:

Simone Fischer, DOAG Dienstleistungen GmbH
(verantwortlich, Anschrift s.o.)

Kontakt: anzeigen@doag.org
Mediadaten und Preise unter: www.doag.org/go/mediadaten

Alle Rechte vorbehalten. Jegliche Vervielfältigung oder Weiterverbreitung in jedem Medium als Ganzes oder in Teilen bedarf der schriftlichen Zustimmung des Verlags.

Die Informationen und Angaben in dieser Publikation wurden nach bestem Wissen und Gewissen recherchiert. Die Nutzung dieser Informationen und Angaben geschieht allein auf eigene Verantwortung. Eine Haftung für die Richtigkeit der Informationen und Angaben, insbesondere für die Anwendbarkeit im Einzelfall, wird nicht übernommen. Meinungen stellen die Ansichten der jeweiligen Autoren dar und geben nicht notwendigerweise die Ansicht der Herausgeber wieder.



9 Nicht nur Google und Facebook profitieren von Big Data



33 Die digitale Transformation ist eine große Herausforderungen

3 Editorial	13 Big Data und All Data in der Cloud <i>Dr. Nadine Schöne und Detlef E. Schröder</i>	27 Mobiliar Performance Warehouse <i>Paolo Kreth</i>
3 Impressum	18 Trinkwasser-Sicherheit mit Predictive Analytics und Oracle <i>Prof. Thomas Bartz-Beielstein, Steffen Moritz und Jan Strohschein</i>	33 Digitale Transformation in Unternehmen <i>Dr. Thomas Kofler</i>
5 Prognose von Herstellkosten-Schwankungen mit Predictive Analytics <i>Alfred Stelzl</i>	24 Location-based, Context-aware Apps auf dem Shopfloor <i>Rolf Scheuch</i>	38 Neues Format „DOAG Meinungsforum“ setzt sich durch <i>Rolf Scheuch</i>
9 Was Big Data kann <i>Peter Welker</i>		



24 Neue Ansätze von Industrie 4.0 und Digitalisierung für die Optimierung von Produktionsprozessen

Unsere Inserenten

DOAG e.V.
www.doag.org

U 2, U 4

E-3 Magazin (B4Bmedia.net) U 3
www.b4bmedia.net

PROMATIS software GmbH S. 15
www.promatis.de



PREDICTIVE ANALYTICS

Prognose von Herstellkosten-Schwankungen mit Predictive Analytics

Alfred Stelzl, Lead Consultant Big Data Analytics

Predictive Analytics (ein deutschsprachiger Begriff existiert bisher nicht) nutzt ausschließlich proaktive Analyse-Techniken, um Vorhersagen über zukünftige Ereignisse oder Kennzahlen zu tätigen. Dabei werden auf Basis umfangreicher Datenanalysen valide Prognosemodelle abgeleitet. Maschinelles Lernen, Statistik und Data Mining spielen eine wesentliche Rolle bei Predictive Analytics. Der Artikel beschreibt einen Proof of Concept (PoC), um Schwankungen bei den Herstellkosten mit Predictive Analytics zu prognostizieren.

Der Wunsch, die Zukunft vorhersagen zu können, entstand mit der Fähigkeit der Menschen, die Zeit wahrzunehmen. Früher waren es die Seher und Propheten, die diese Bedürfnisse befriedigten. In der heutigen modernen Welt sind dafür die Informatik, fortgeschrittene Analysen mit Predictive Analytics und maschinelles Lernen zuständig. Man könnte sich dabei die Frage stellen, weshalb Prognosen so interessant sind. Die Antwort ist relativ einfach: Das Bedürfnis, ein kommendes Ereignis vorherzusehen, entsteht aus dem Verlangen nach Sicherheit und Gewissheit. Die Nach-

frage nach Prognosen wächst, sobald die subjektiv empfundene Unsicherheit steigt [1, Seite 32].

Diese allgemeine Erkenntnis lässt sich sinngemäß auf die immer stärker vernetzte Welt übertragen. Längst werden immer größere Datenmengen weitgehend in Echtzeit bearbeitet und analysiert. Produktionsstrukturen sind eng verzahnt und exakt aufeinander abgestimmt. Die Puffer, um Schwankungen ausgleichen zu können, sind in der Folge auch kleiner geworden. Die Analyse und Steuerung solcher Schwankungen und der damit verbunde-

nen Unsicherheiten ist laut einer Zukunftsstudie der Wissenschaftlichen Hochschule für Unternehmensführung (WHU) ein zentrales Thema der nächsten Jahre. Das Ausmaß an Schwankungen wird oft als „Volatilität“ bezeichnet und hat vielerlei Facetten. Welche Messgröße verwendet wird, hängt von der unternehmensspezifischen Betroffenheit ab [2, Seite 7].

In diesem PoC wird die Volatilität in den Kontext der Kostenschwankung gesetzt und untersucht. Dafür werden historische Daten mithilfe von Predictive Analytics und der Methoden des maschinellen Lernens



Abbildung 1: Beispiel für Schwankungen bei Gütertransporten

analysiert. Predictive Analytics ist hierbei ein Werkzeug, um zukunftsbezogene Informationen zur Entscheidungsunterstützung bereitzustellen [3, Seite 519]. Die Leitfrage des PoC lautet: Wie gut kann die Volatilität der Herstellkosten mit Predictive Analytics und dem Einsatz von maschinellen Lernverfahren prognostiziert werden?

Der Use Case

Der Fall bezieht sich auf den Angebotsprozess eines Kunden. Die Herstellkosten (HK) bilden eine zentrale Kosteninformation und spiegeln die Produktionskosten von Gütertransporten wider. In der Vorkalkulation werden die Herstellkosten auf Basis verschiedener Attribute für einen Transport berechnet, um eine erste Indikation der Kosten im Angebotsprozess zu erhalten. Die Problemstellung ist, dass unterschiedliche oder instabile Produktionsstrukturen schwankende Her-

stellkosten erzeugen und zu einer Volatilität führen. *Abbildung 1* zeigt, wie es zu schwankenden Herstellkosten bei Gütertransporten kommen kann.

Je stärker die Herstellkosten schwanken, desto unvorhersehbarer ist letztendlich die Marge. Es bedarf Früh-Indikatoren und Steuerungsinstrumente, um auf die Volatilität in der Angebotsphase entsprechend reagieren zu können. *Abbildung 2* zeigt die Anwendung der Predictive-Analytics-Lösung innerhalb der Angebotsphase einschließlich des Kundennutzens.

Proof of Concept

Ziel ist es, die Rentabilität der Angebote durch die Vorhersage der prozentualen Schwankung der Herstellkosten zu verbessern. Weitere Ziele des PoC lauten:

- Messung der Prognosegüte der Modelle

- Methodik solcher Projekte kennenlernen
- Identifikation von neuem Wissen über Schwankungen der Herstellkosten
- Keine operative Implementierung der Modelle

Die Architektur

Die Quelldaten werden aus einer Oracle Exadata und einem MS-SQL-Server extrahiert und anschließend mit RapidMiner In-Memory weiterverarbeitet. RapidMiner ermöglicht eine grafische Modellierung von Prozessen, in denen einzelne Operatoren die analytischen Funktionalitäten wiedergeben. Als Erweiterungen werden die Extensions Feature Selection, Parallel Processing und Waikato Environment for Knowledge Analysis (WEKA) eingebunden und verwendet. Die Extensions Feature Selection und WEKA bieten zusätzliche Algorithmen für die Variablen-Selektion oder zur Modell-Erstellung. Parallel Processing ermöglicht bei bestimmten Algorithmen die parallele Verarbeitung innerhalb der Trainings- und Validierungsphase.

Die Vorgehensweise

Als methodische Vorgehensweise kommt beispielsweise der CGI Analytics Lifecycle zum Einsatz, der für Big-Data-Analytics-Projekte empfohlen wird (siehe *Abbildung 3*). Er beschreibt die typischen Phasen eines Projekts einschließlich der auszuführenden Arbeiten. Als Prozessmodell bietet er einen Überblick über den Predictive-Analytics-Lebenszyklus. Der Prozess beinhaltet folgende Phasen:

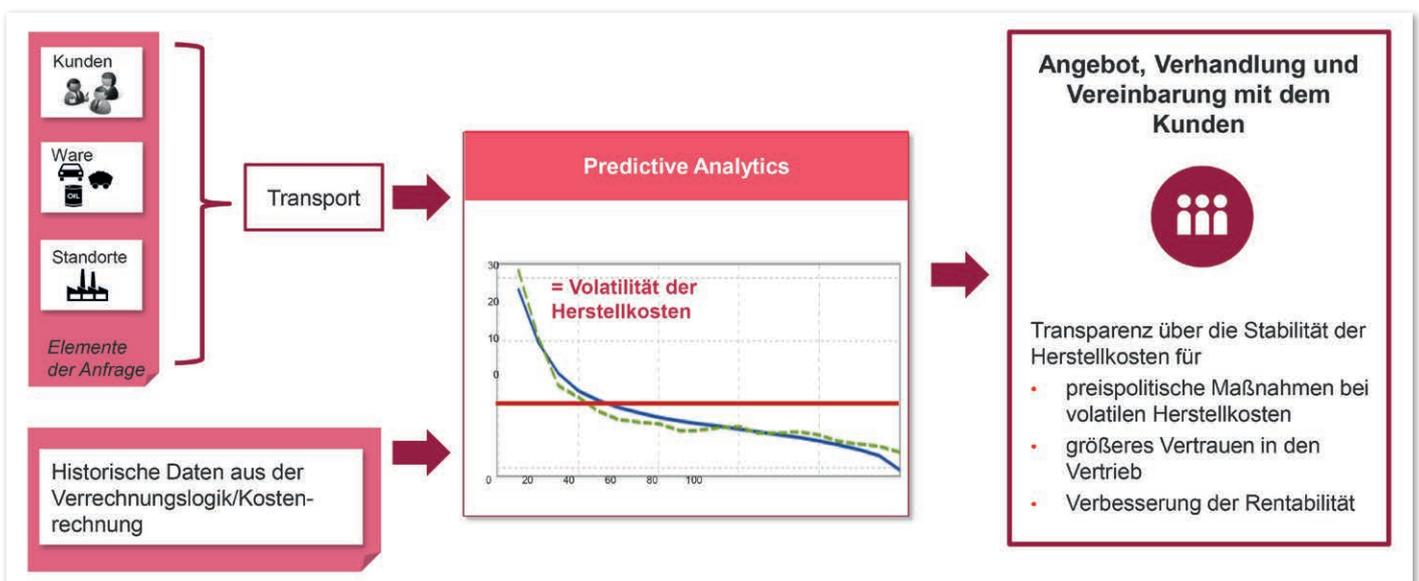


Abbildung 2: Predictive-Analytics-Lösung mit Kundennutzen

- Business Insights
 - Verständnis der fachlichen Aufgabenstellung und Problemstellung
 - Verständnis der derzeitigen Prozesse und Anwendungen
 - Festlegung der Ziele
- Data Understanding
 - Verständnis der benötigten Datenquellen
 - Sammlung, Zusammenführung und Analyse der benötigten Daten für den Anwendungsfall
 - Erforschung der Daten, um Kenntnisse über Form, Inhalt und Struktur zu erlangen
- Data Modeling
 - Aufbereitung der Quelldaten zu einem analysefähigen Bestand
 - Vereinigung und Aggregation der Daten
 - Bereinigung, Umcodierung, Formatierung, Erstellung neuer Daten und Auswahl der Trainings- beziehungsweise Test-Daten
- Analytics Modeling
 - Auswahl der Algorithmen auf Basis der Datengrundlage oder Art der Fragestellung
 - Erstellung, Validierung und Evaluierung der Modelle
 - Berechnung der Gütemaße innerhalb der Trainings-, Validierungs- und Test-Prozesse
- Analytics Deployment
 - Bereitstellung der Ergebnisse für die Nutzung
 - Deployment der Modelle in operative Systeme

Die Modell-Erstellung

Das Modell basiert auf dem Ansatz des maschinellen Lernens. Es bezeichnet einen Prozess, bei dem künstliche Systeme Wissen aus Erfahrungen generieren. Da künstliche Systeme nicht wie Menschen über Erfahrungen verfügen, müssen diese mithilfe von Daten erlernt werden. Die Algorithmen des maschinellen Lernens erkennen in den historischen Daten (komplexe) Muster und Regelmäßigkeiten, die in Form eines mathematischen Modells gespeichert sind [4, Seite 179].

Als Methode kommt überwachtetes Lernen (englisch: Supervised Learning) zum Einsatz. Dabei wird versucht, anhand von Trainingsdaten die Zusammenhänge und Beziehungen zwischen den Eingabe- und Ausgabe-Variablen (Ziel-Variablen) zu identifizieren und zu erlernen. Das daraus resultierende Modell

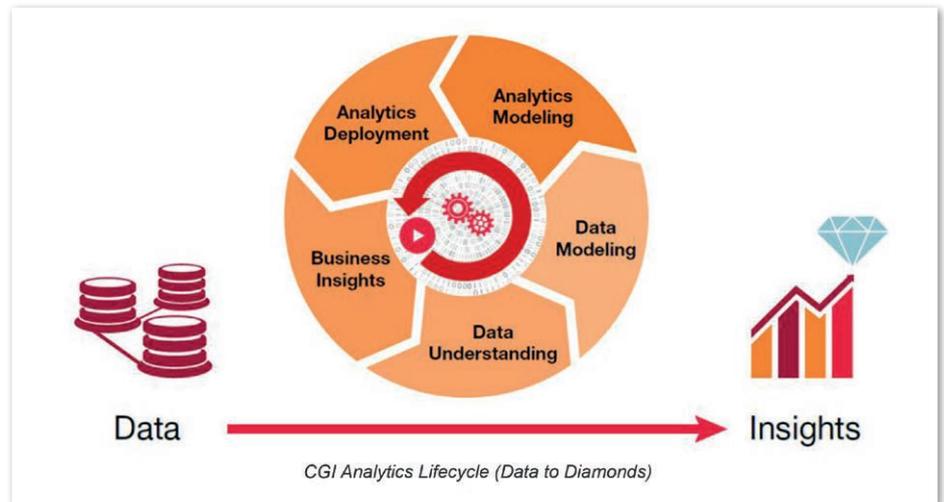


Abbildung 3: CGI Analytics Lifecycle (Data to Diamonds)

verallgemeinert die Beziehung zwischen den Variablen und verwendet sie für neue Datensätze (Instanzen), um die Ziel-Variable vorherzusagen. Wichtig ist dabei, dass für jedes einzelne Trainingsbeispiel sowohl alle Werte der Eingabevariablen als auch alle Werte der Zielvariablen vorgegeben sind [5]. Die Modellierung wird mit der multiplen linearen Regression (MLR) und dem M5Prime-Modellbaum (M5') durchgeführt. Beide Algorithmen eignen sich für metrisch skalierte Zielvariablen.

Die multiple lineare Regressions-Analyse ist ein statistisches Verfahren, das eine Beziehung zwischen abhängiger (Ziel-Variable) und unabhängigen Variablen (Eingabe-Variablen) als lineare Funktion darstellt. Im Fall einer unabhängigen Variablen spricht man von univariater Regressions-Analyse, bei mehreren unabhängigen Variablen von multipler Regressions-Analyse [6, Seite 106].

Der M5'-Modellbaum-Algorithmus ist ein Verfahren für Entscheidungsbäume zu Regressionszwecken. Er erzeugt einen Modellbaum, der lineare Modelle in den Blättern speichert. Zusätzlich wird neben den weiterentwickelten Pruning-Methoden das sogenannte „Smoothing“ als Glättungsverfahren für die Prognosewerte eingesetzt, um die Genauigkeit weiter zu erhöhen [7, Seite 343]. Die Komplexität eines Modells hängt von der Anzahl der unabhängigen Variablen ab. Speicher- und Laufzeitverhalten eines maschinellen Lernprozesses sind dadurch festgelegt. Die Methoden der Variablen-Selektion (Feature-Selection) helfen unter anderem, die unwichtigen Variablen herauszufiltern. Für die MLR wird eine separat modellierte Correlation-Based-Feature-Selection verwendet, die auf einer einfachen Korrelations-Analyse aufbaut. Für den M5'-

Modellbaum kommt eine Forward-Selection zur Variablen-Selektion zum Einsatz. Sie prüft die Variablen einzeln daraufhin, ob sie in das Modell aufgenommen werden oder nicht. Nur Variablen, die die Prognosegüte steigern, verbleiben im Modell.

Beide Modell-Algorithmen werden jeweils mit einer Kreuz-Validierung verarbeitet, um eine Überanpassung (Overfitting) des Modells an die Trainingsdaten zu erkennen. Die Kreuz-Validierung zerlegt die Gesamt-Datenmenge in möglichst gleich große Teile (Folds). Für jede Teilmenge wird in einem iterativen Prozess ein Modell trainiert und anschließend mit den übrigen Teilen getestet, um Gütemaße zu berechnen [8].

Die Abbildungen 4 und 5 zeigen schematisch die Modellierung der multiplen linearen Regression und des M5'-Modellbaums in RapidMiner. Die gespeicherten Modelle werden anschließend in Testprozesse übernommen, um die Modelle auf neue, noch nicht verarbeitete Daten zu testen.

Die Evaluierung

Für beide Algorithmen werden folgende Gütemaße in den Trainings-, Validierungs- und Testprozessen berechnet:

- R2
Das Bestimmtheitsmaß gibt prozentual an, wie gut die Anpassung des Modells an die beobachteten Punkte ist.
- RMSE
Der Root Mean Square Error ist ein Maß für den Prognosefehler des Modells. Er besitzt die gleiche Einheit wie die Zielvariable.

Table 1 zeigt eine Übersicht der Ergebnisse.

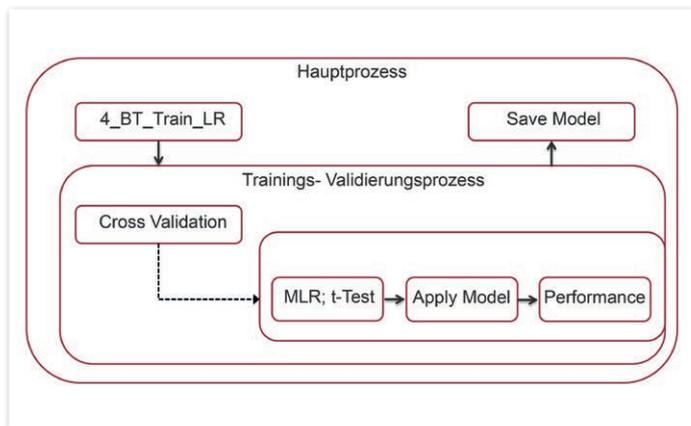


Abbildung 4: Modellierung multiple lineare Regression

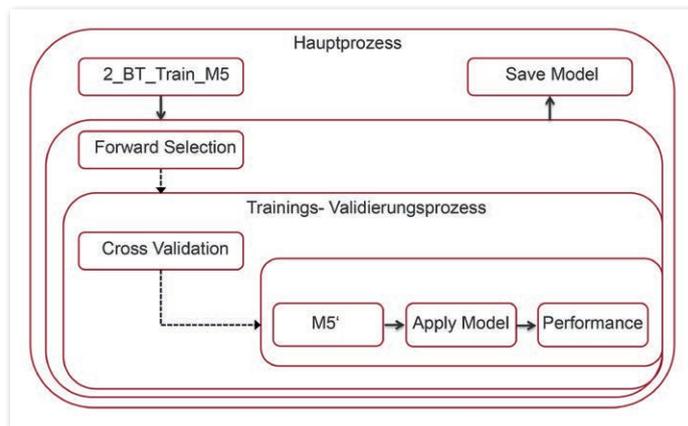


Abbildung 5: Modellierung M5'-Modellbaum

Der M5'-Modellbaum schneidet bei allen drei Bewertungsmaßen geringfügig besser ab als die multiple lineare Regression. R2 für die Trainingsdaten liegt beim Modellbaum bei 0,48 und bei der multiplen linearen Regression bei 0,44. Ein R2 von 0,5 kann bei einer Querschnittsbetrachtung bereits als guter „fit“ eingestuft werden. Die RMSE-Werte liegen bei beiden Modellen deutlich unter der Standardabweichung der abhängigen Variablen mit 12 Prozent.

Die Zusammenfassung

Die Ergebnisse des PoC zeigen, dass die Modelle nahezu identische Werte in der Genauigkeit der Prädiktion innerhalb der Trainings- und Testdaten liefern. Das M5'-Modell ist bei allen Bewertungsmaßen besser als die multiple lineare Regression. Beide Modelle weisen kein Overfitting auf, was durch eine genauere Prädiktion in den Testdaten festgestellt werden kann und somit den Einsatz der aufwändigen Variablen-Selektion und Kreuz-Validierung bestätigt.

Beim Bestimmtheitsmaß ist der Unterschied zwischen den Modellen größer. Das M5'-Modell liefert hier gute Werte. Keines der Modelle erreicht den gewünschten RMSE unter 5 Prozent; jedoch liegen die Modelle mit M5' von 8,7 Prozent und MLR von 8,9 Prozent deutlich unter der Standardabweichung der Zielvariablen von 12 Prozent.

Beide Modelle selektieren die Variable „Branche“ als wichtigstes Merkmal für die Schwankung der Herstellkosten. Bisherige Annahme innerhalb des Unternehmens war, dass „Gutart“ den höchsten Einfluss hat. Eine weitere Iteration ergab sehr gute Prognosewerte (RMSE-Test ungefähr 2 Prozent) für die jeweilige Branche.

Der PoC zeigt zudem auf, dass Predictive-Analytics-Projekte sehr umfangreich, kreativ und iterativ sind, bei denen ein „Fail Fast“ erlaubt sein muss. Die Daten verlangen besonders viel Aufmerksamkeit, bevor sie mit Algorithmen weiterverarbeitet werden können. Folgende Aspekte sind dabei wichtig:

- Inhalte und Qualität der Quelldaten müssen geprüft und verstanden werden. Was bedeuten die einzelnen Attribute fachlich und welche Ausprägungen sind vorhanden? Gibt es Ausreißer, fehlende oder ungültige Werte? Sind Nachbesserungen erforderlich, etwa das Korrigieren fehlerhafter Ausprägungen oder Ersetzen fehlender Werte mit sinnvollen Inhalten?
- Ist der Umfang der vorhandenen Dateninhalte ausreichend? Benötigt man für die Analyse neue, aus den Daten abgeleitete Attribute?
- Müssen weitere Datenquellen zusammengeführt und aggregiert werden, um ein brauchbares Ergebnis zu erzielen?

Fazit

Langfristig betrachtet ist die Entwicklung eines Systems zur Prognose der Volatilität der Herstellkosten von hohem Interesse. Dadurch können Schwankungen rechtzeitig erkannt und gerade in volatilen Zeiten Wettbewerbsvorteile generiert werden.

Literaturverzeichnis

- [1] Weber, R. (2000): Prognosemodelle zur Vorhersage der Fernsehnutzung, München, Reinhard Fischer
- [2] Schäffer, U., Bechtoldt, C., Grunwal-Delitz, & Reimer, T. (2014), Steuern in volatilen Zeiten, Weinheim, Wiley-VCH
- [3] Mertens, P., & Rässler, S. (2012), Prognoserechnung, Heidelberg, Physica-Verlag, Morgan Kaufmann
- [4] Ertel, W. (2008), Grundkurs Künstliche Intelligenz, Wiesbaden, Vieweg & Teubner
- [5] Deshpande, B., und Kotu, V. (2014), Predictive Analytics and Data Mining, Amsterdam, Morgan Kaufmann
- [6] Pruscha, H. (2006), Statistisches Methodenbuch, Heidelberg, Springer
- [7] Quinlan, J. (1992), Learning With Continuous Classes, Proceedings of the Fifth Australian Joint Conference on Artificial Intelligence
- [8] Provost, F., & Fawcett, T. (2013), Data Science for Business, Kalifornien, O'Reilly Media

Algorithmus	R2 Training	RMSE-Validierung	RMSE-Test
MLR	0,44	9,026	8,905
M5'	0,48	8,927	8,734

Tabelle 1: Übersicht der Ergebnisse



Was Big Data kann

Peter Welker, DOAG-Themenverantwortlicher Big Data

Nicht nur Google und Facebook oder die Geheimdienste profitieren von Big Data. Fast jedes Unternehmen tut es bereits – direkt oder indirekt. Die Frage ist, wann man in eigene Lösungen investiert, wann eher in externe Services und wie viel Spielraum man der Entwicklung neuer Ideen gewährt.

Es ist nichts Neues mehr, dass heute in fast jeder Situation für fast jeden Menschen und durch fast jede Maschine Unmengen von Daten permanent produziert und gesammelt werden. Spannend wird es aber, wenn man die Vielfalt der Daten betrachtet und die möglichen Zusammenhänge der verschiedenen Datenquellen analysiert: Welche Daten sind denn überhaupt verfügbar und was davon kann/darf für welchen Zweck genutzt werden?

Das Internet und seine Spione

Lästige und gefährliche Spionage-Software gibt es seit Langem. Damit sind nicht etwa Viren und Trojaner gemeint, sondern Internet-Werbetracker, Browser-Add-ons oder Ad-beziehungsweise Spy-Ware, die Huckepack auf gängigen Software-Lösungen reist. Mit ihrer Hilfe erstellen spezialisierte Unternehmen umfangreiche Web-Profile von Millionen Nutzern und bieten diese

zum Verkauf an, wobei solche Profile weit mehr Informationen beinhalten, als man gerne selbst bekanntgeben würde – bis hin zur Identifikation der betroffenen Personen (siehe „<http://www.ndr.de/nachrichten/netzwelt/Nackt-im-Netz-Millionen-Nutzer-ausgespaehrt,nacktimnetz100.html>“).

Solche – bestenfalls in einer Grauzone verortbaren – Big-Data-Anwendungen sind jedoch nur die unrühmliche Spitze des Eisbergs.

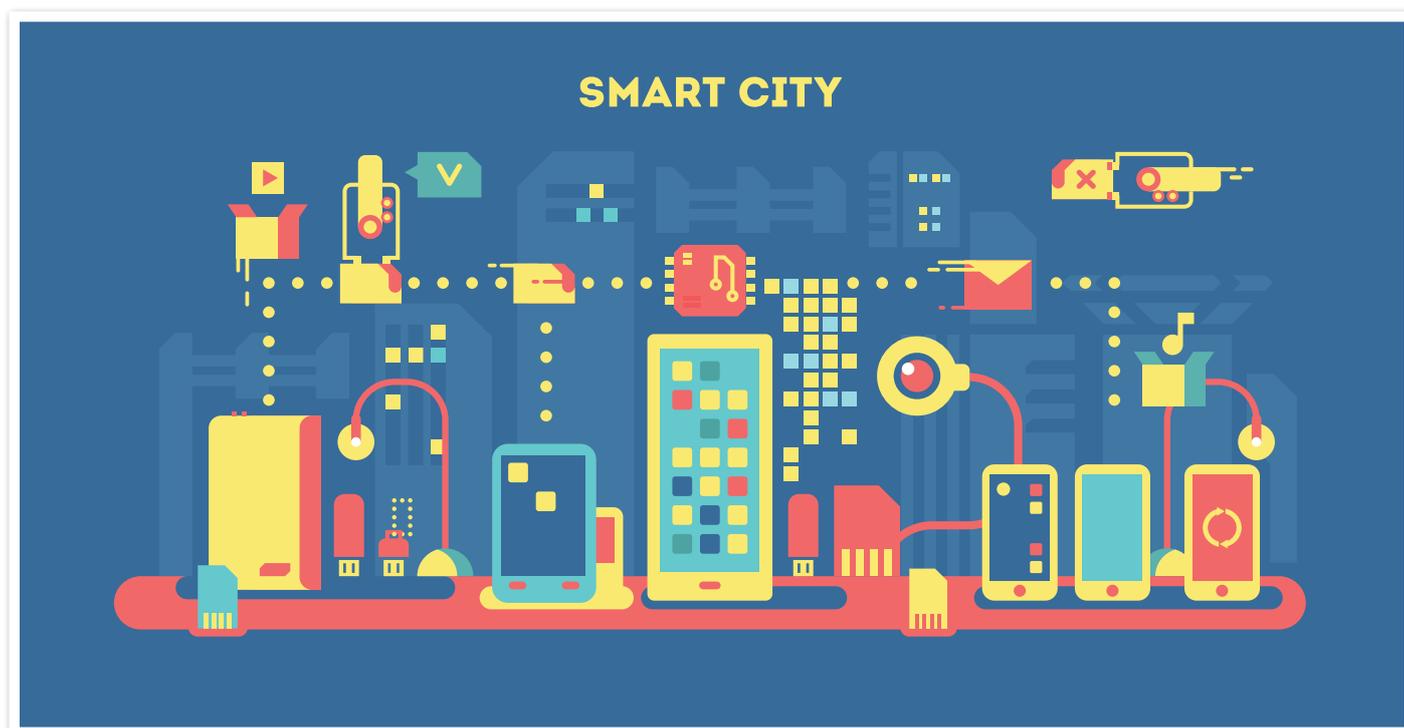


Abbildung 1: Smart City

Darunter liegen immense, vielfältige und oft weit unbedenklichere Informationen, die man für unterschiedlichste Zwecke nutzen kann.

Open Data und smarte Städte

Bei Open Data in den Städten geht es vor allem, aber nicht nur, um Transparenz, um Entscheidungsprozesse und daraus abgeleitete Maßnahmen zur Stadtplanung offen zu kommunizieren. Vielmehr sollen alle wichtigen Daten für jeden zugänglich gemacht werden (siehe Abbildung 1). Dazu gehören neben Sensordaten zu Wetter und Umweltbedingungen auch solche zur Integration von öffentlichem Nahverkehr und Car-Sharing oder Daten zu Energie-Produktion und -Austausch in Gebäuden oder Bezirken (siehe „<https://ec.europa.eu/inea/en/horizon-2020/smart-cities-communities>“). Neben New York hat beispielsweise Chicago inzwischen fast 400 Datenquellen – von der Kriminalitätsverteilung über Lobbystrukturen bis hin zu allen Taxifahrten der letzten Jahre – öffentlich verfügbar gemacht (siehe „<https://data.cityofchicago.org/>“); und zwar nicht einfach in annähernd undurchsuchbaren Dokumenten, sondern strukturiert in Datenbanken inklusive Such- und Download-Option.

Was man mit solchen Daten anfangen kann, zeigt beispielsweise Todd Schneider in seiner vergleichenden Analyse von Taxi- und Uber-Fahrten (siehe „[\[schneider.com/posts/analyzing-1-1-billion-nyc-taxi-and-uber-trips-with-a-vengeance\]\(http://toddw-schneider.com/posts/analyzing-1-1-billion-nyc-taxi-and-uber-trips-with-a-vengeance\)“\): Neben zahlreichen Tipps zur richtigen Zeitplanung bei Taxifahrten kann man sehen, dass Uber innerhalb eines Jahres um den Faktor 5 wuchs und dabei in Brooklyn deutlich die Yellow-Cab-Fraktion überholte, was interessante Prognosen rund um die Taxi-Situation in New York zulässt. Ein weiteres Beispiel: Ben Wellington entdeckte einen 800-Millionen-Dollar-Tippfehler im Polizeibudget von New York \(siehe „<http://iquantny.tumblr.com/post/147446103684/open-data-reveals-791-million-error-in-newly>“\) – was offenbar keinem der Verantwortlichen vorher aufgefallen war.](http://toddw-</p>
</div>
<div data-bbox=)

Das verdeutlicht einen wesentlichen Aspekt der neuen Daten: Daraus ableitbare Erkenntnisse sind nur selten vorhersehbar. Man gewinnt sie erst bei deren Analyse, was in vielen Unternehmen die liebgewonnene „Business Case First“-Prämisse für die IT auf den Prüfstand stellt: In diesem Fall gilt es, zunächst vorbehaltlos in die (Daten-) Forschung zu investieren und der explorativen Analyse von Daten deutlich mehr Spielraum einzuordnen.

Die Telekommunikation und die Massenbewegung

Im kommerziellen Umfeld sind – neben beispielsweise Google mit seinen Ortungs-

Daten ausgestattet, die es erlauben, jedes Mobiltelefon in Reichweite der Funkantennen eindeutig zu identifizieren, zu lokalisieren und, sofern es sich um einen Kunden handelt, auch den Nutzer dahinter auszumachen. Bei eingeschaltetem Handy ist so der Aufenthaltsort jedes Teilnehmers qualifizierbar – und die Bewegung des Nutzers über die Zeit somit auch. Das ermöglicht das Erstellen detaillierter Bewegungsprofile (siehe Abbildung 2).

Die Nutzung dieser Informationen im Zusammenhang mit dem individuellen Nutzer beispielsweise zu Werbezwecken ist bei uns aus Datenschutzgründen nicht erlaubt. Einzige Ausnahme ist die Verwendung zu Ermittlungszwecken mit richterlichem Beschluss in jedem einzelnen Fall. Wenn die Daten aber ausreichend anonymisiert sind, sodass sie keinerlei Rückschlüsse auf die Personen mehr zulassen, sind dennoch sehr wertvolle Informationen erhältlich. So kann beispielsweise die Swisscom in der Schweiz mit diesen Verfahren sehr zuverlässige und feingranulare Aussagen über den gegenwärtigen Straßenverkehr machen und damit die Straßen- und Baustellenplanung unterstützen (siehe <https://www.swisscom.ch/de/emag/editions/dialogue0115/fokus/interview.html>). Zudem lassen sich Pendlerströme visualisieren oder Transit von rein regionalem Verkehr unterscheiden, um beispielsweise die Parkhaus-Situation zu verbessern

(siehe „<https://www.hslu.ch/de-ch/informatik/news/2016/09/30/big-data-seminar-praxis-beispiele-swisscom>“).

Für solche Daten wurde der Begriff „Big Data“ erfunden: Datenmengen, die in kurzer Zeit die Petabyte-Grenze („Volume“) überschreiten und auch nach Jahren noch interessant sind, um beispielsweise den Erfolg von Maßnahmen zu überprüfen. Solche Daten müssen langfristig gespeichert werden. Auf der anderen Seite benötigen manche Anwendungsfälle wie eine Stauwarnung sehr zeitnahe Werte, bedingen also eine sehr kurze Latenz („Velocity“). Zudem muss die Unabhängigkeit von den Datenstrukturen sichergestellt sein („Variety“).

Während bei relationalen Datenbanken die Datenstruktur meist vorab bekannt ist, muss das bei der Datenablage in Filesystemen wie Hadoop, aber auch in vielen NoSQL-Datenbanken, nicht der Fall sein. Hier genügt es, erst beim Lesen der Daten über deren Struktur Bescheid zu wissen. Damit ermöglicht man das vorausschauende Speichern von Daten, die heute noch nicht eingesetzt werden, in Zukunft jedoch von Bedeutung sein können.

Industrie, Energie und „Sensing as a Service“

Gerade moderne Maschinen produzieren extreme Datenmengen. Eine einzige Flugzeugturbine ist mit bis zu 5000 Sensoren bestückt, deren Daten zum Beispiel genutzt werden, um Treibstoff zu sparen oder Maschinenausfälle besser zu prognostizieren (siehe „<http://www.businesscloudnews.com/>



Abbildung 2: Bewegungsdaten

2014/07/21/pratt-whitney-ibm-team-on-aircraft-engine-performance-monitoring-with-big-data“) („Predictive Maintenance“).

Für Stromerzeuger und Übertragungsnetzbetreiber ist wiederum die möglichst genaue Prognose der Energie-Erzeugung und des Verbrauchs am nächsten Tag ein entscheidender Faktor. Weil das Stromnetz selbst nicht für Speicherung und Abruf der Energie genutzt werden kann, müssen hier Verbraucher und Produzenten möglichst schnell reagieren. Dabei sind Kraftwerke und Verbraucher, die man in Sekunden oder Minuten abschalten oder anfahren kann, eher dünn gesät. Wird der Verbrauch also

nicht vorab korrekt geschätzt, müssen diese sogenannten „Regelleistungen“ in hohem Maße abgerufen werden, was bestenfalls hohe Kosten verursacht, schlimmstenfalls aber auch zu Stromausfällen führen könnte. In Zeiten zunehmender Wind- und Sonnen-Energie spielen also regionale Wettervorhersagen eine immer wichtigere Rolle.

In diesem Zusammenhang verwundert es auch nicht mehr, dass IBM im Jahr 2015 die „Weather Company“ gekauft hat (siehe „<http://www.marketwatch.com/story/ibm-finally-reveals-why-it-bought-the-weather-company-2016-06-15>“). Während zunächst noch geunkelt wurde, ob IBM den Begriff „Cloud“ missinterpretiert habe, kündigte IBM eine Mikrowetter-Vorhersage mit zum Teil unter einem Kilometer Genauigkeit an. Mit diesen Daten will IBM seine Kunden mit besseren, individuellen Kurzzeitvorhersagen im Zeitraum von maximal 84 Stunden versorgen (siehe Abbildung 3).

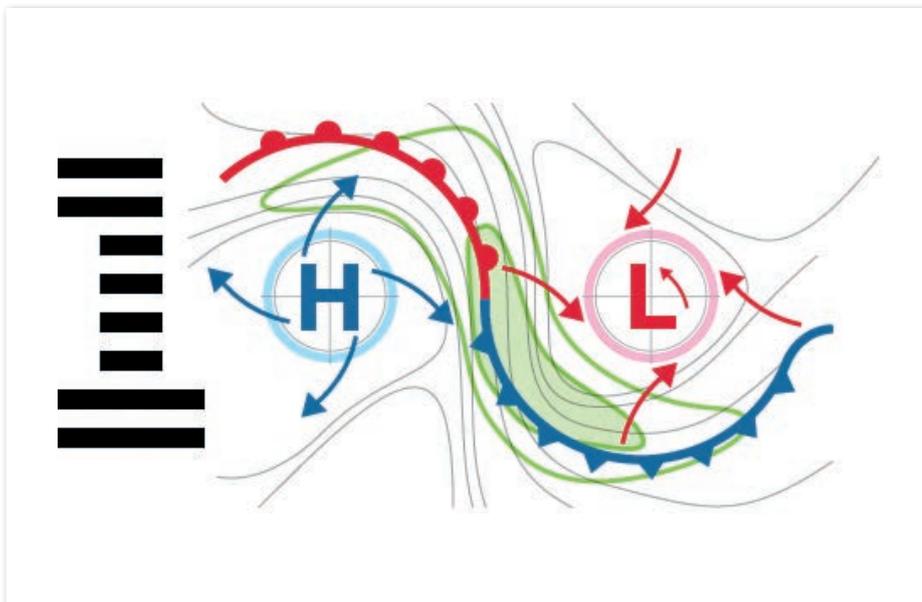


Abbildung 3: IBM Deep Thunder (Quelle: IBM)

Neue Ideen und das semantische Netz

Im Prinzip lassen sich all die verschiedenen Daten auch miteinander verknüpfen und dadurch neue Anwendungsfälle ersinnen. So können Veranstaltungskalender, Wetter-Informationen und gut geschätztes Passanten-Aufkommen in manchen Fällen für lokale Werbezwecke oder in anderen Fällen für eine angepasste Polizeipräsenz genutzt werden. Oder die Tourismus-Industrie interpretiert Tweets und andere Social-Media-Äußerungen zur Sentiment-Analyse und Bewegungsdaten zur Verifikation von

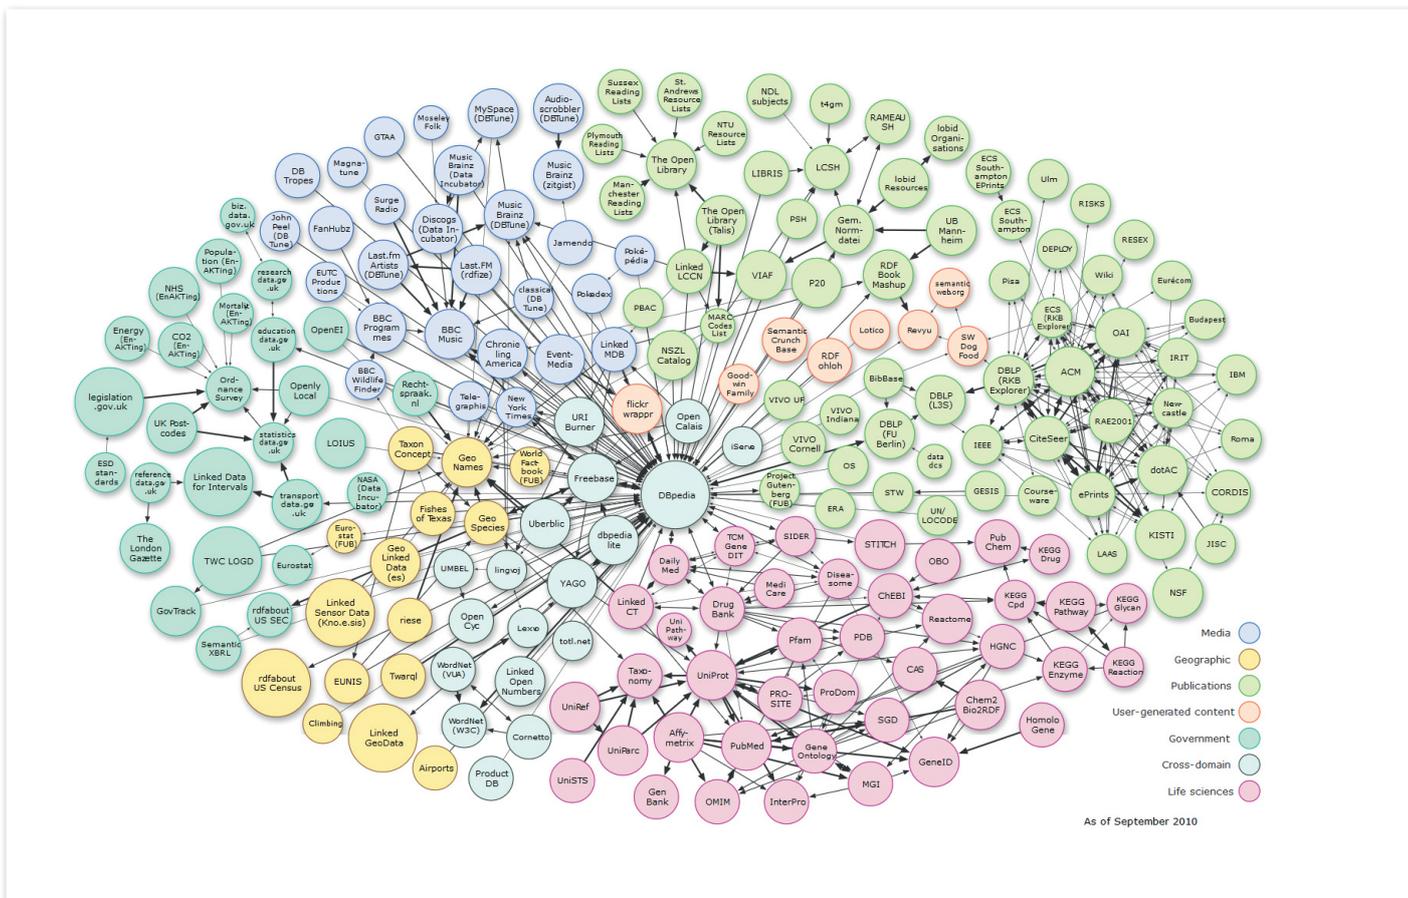


Abbildung 4: Linked Datasets im Semantic Web

Werbe-Initiativen. Die Möglichkeiten sind endlos – welche davon auch erfolgreich sind, wird sich über die Zeit herausstellen.

Wie nützlich die zusammengeführten Daten wirklich sind, ist allerdings nicht zuletzt auch davon abhängig, wie gut und einfach sich die Informationen überhaupt verknüpfen lassen. Hier kommt ein weiteres – oft unterschätztes – Puzzleteil ins Spiel: die Metadaten. Die Heterogenität neuer und alter, interner und externer Daten macht die Integration nochmals um ein Vielfaches komplizierter. Die Lösung dafür heißt „Semantic Web“ und wurde schon vor fünfzehn Jahren konzipiert und standardisiert, um Daten aus dem World-Wide-Web maschinenlesbar zu verknüpfen. Nachdem es lange Zeit eher ein Nischendasein fristete, hat sich die Semantic-Web-Technologie in den letzten Jahren unter anderem in der Pharma-Branche etabliert (siehe Abbildung 4).

Dabei sind Möglichkeiten und Erfolge dieser Technologie beachtlich. Zum Beispiel hat sich DBpedia (siehe „<http://de.dbpedia.org>“) zum De-facto-Standard in diesem Umfeld gemauert. DBpedia ist die Semantic-Web-Version von Wikipedia und stellt die Inhalte von Millionen Artikeln in einem direkt ma-

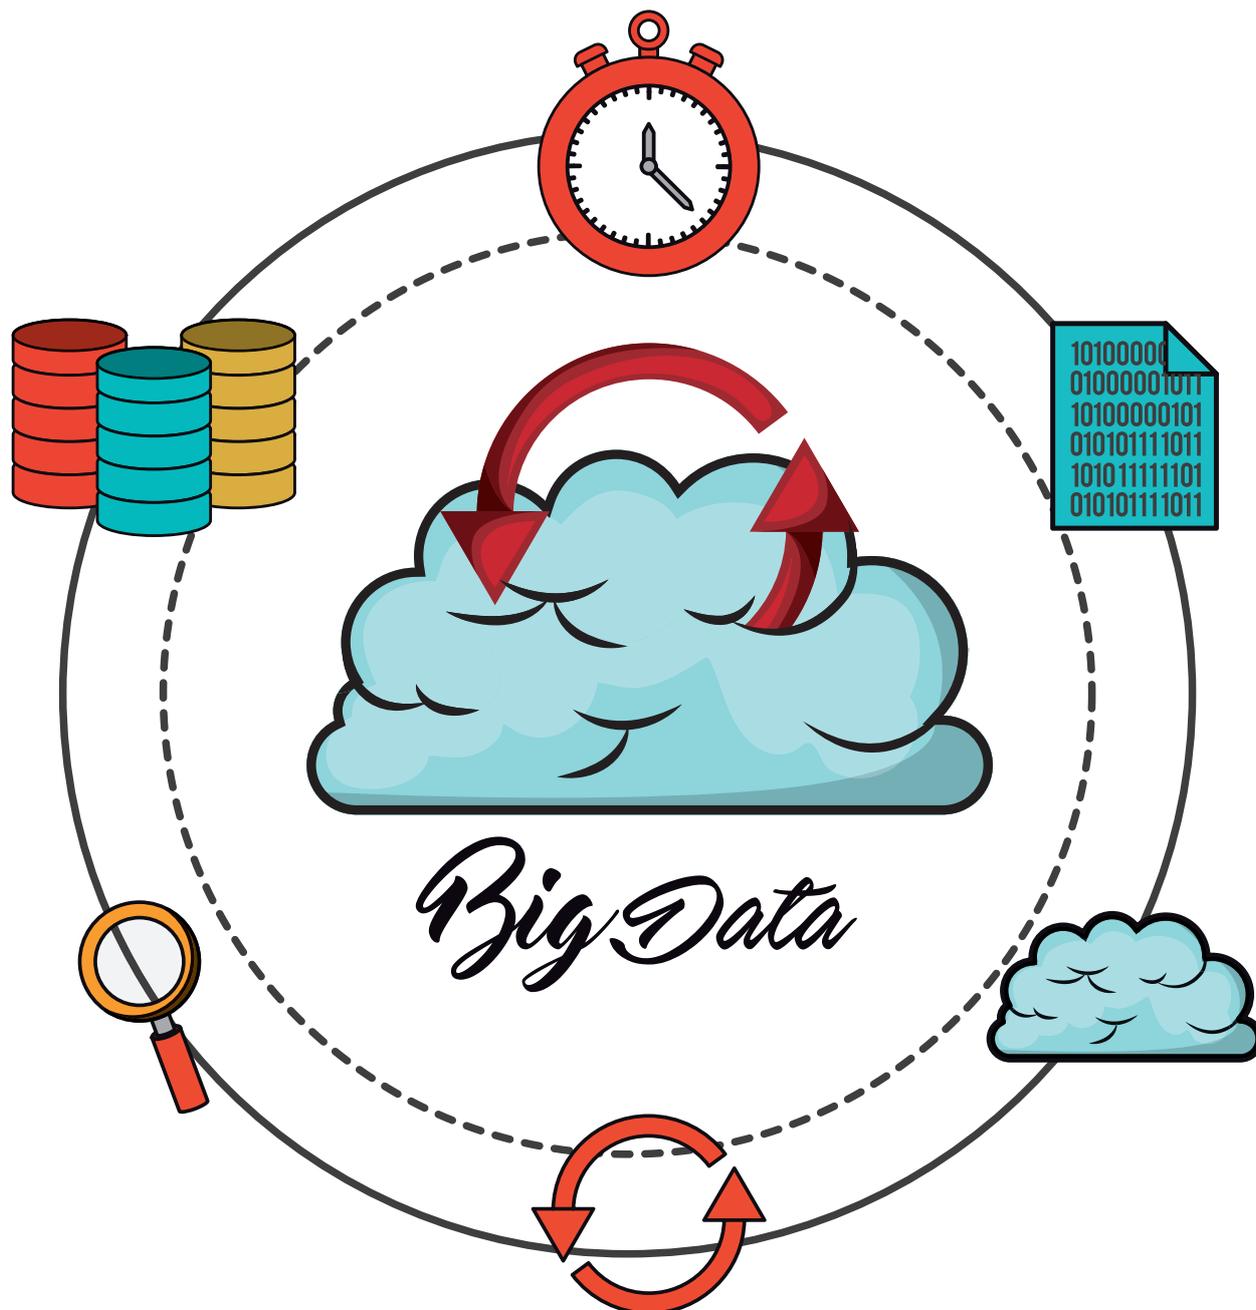
schinenlesbaren Format frei zur Verfügung. Ähnlich gibt es Hunderte andere Projekte und Organisationen, die so einen weltweiten Standard definiert haben, in dem Hunderte Millionen von Objekten und Definitionen aus der realen Welt inklusive ihrer Zusammenhänge modelliert und nutzbar sind. Mit diesen Vorgaben lassen sich nicht nur eigene Daten entsprechend standardisieren, sondern auch weltweit übergreifend verknüpfen.

So haben unter anderem die Pharma-Unternehmen Roche und Novartis im Semantic-Web-Umfeld einiges getan, um in der Forschung und Entwicklung interne und externe Daten unterschiedlichster Herkunft zu verknüpfen, zu standardisieren und mit weit aussagekräftigeren Metadaten zu versehen, als es beispielsweise in relationalen Datenbanken üblich ist. Dadurch können bisher unerkannte Zusammenhänge leichter entdeckt und aufwendige Recherchen vereinfacht werden.

Fazit

Big Data & Co. sind inzwischen in den Unternehmen angekommen. Während vieler-

orts immer noch experimentiert wird, sind einige Vorreiter auch außerhalb der IT-Szene bereits mit den neuen Daten, Technologien und Methoden produktiv. Viele neue Ideen bilden sich auf diesen Daten und Services; neue Geschäftsmodelle etablieren sich rasant. Es lohnt sich, diesen Ideen ausreichend Spielraum einzuräumen.



Big Data und All Data in der Cloud

Dr. Nadine Schöne und Detlef E. Schröder, ORACLE Deutschland B.V. & Co. KG

Big Data und Cloud? Je nachdem, wo die Daten herkommen oder wie sie strukturiert sind, kann die Nutzung von Cloud-Services auch beim Thema „Big Data“ Vorteile bringen. Neue Ansätze lassen sich schnell und einfach in einer Cloud-Umgebung testen – so könnte man zum Beispiel sicher und flexibel in die Internet-of-Things (IoT)-Welt starten. Dieser Artikel zeigt die Möglichkeiten der Datenhaltung und Bearbeitung in der Cloud – sowohl komplett in der Cloud, hybrid oder auch als „Cloud at Customer“-Lösung.

In den letzten Jahren haben mehr und mehr Firmen und Organisationen Big-Data-Technologien adaptiert, um auf Basis von Daten-Analysen faktenbasierte Entscheidungen zu treffen. Erfahrungsgemäß sind für den Erfolg sowohl die IT-Architektur als auch Organisationsprinzipien entscheidend. Wenn Daten nicht effektiv organisiert und bereitgestellt werden, steigen die Kosten, während der Nutzen für das Unternehmen sinkt. Daten sind ein neues Kapital, und nicht nur die Menge ist entscheidend, sondern auch, was man damit anstellt.

Daten oder Big Data?

Wann werden Daten zu Big Data? Oft wird versucht, relationale Daten und Big Data gegenüberzustellen. Es gibt jedoch keine stringente Abgrenzung. Deshalb ist es auf jeden Fall sinnvoll, eine neue Big-Data-Plattform eng mit bestehenden Strukturen zu verzahnen – „All Data“ statt „Data und Big Data“.

Zudem erhöht der Aufbau einer separaten Big-Data-Plattform erst einmal nur die Komplexität der IT-Infrastruktur und verursacht zusätzliche Kosten. Ein Mehrwert wird erst durch die Verzahnung mit der bestehenden IT-Infrastruktur entstehen – durch zusätzliche Erkenntnisse mithilfe von Daten-Analysen, die ohne die neue All-Data-Plattform nicht möglich gewesen wären.

Relationale Datenbanken, klassische Data Warehouses, Hadoop, aber auch NoSQL-Datenbanken können Bestandteile einer All-Data-Plattform sein. Solch ein Konstrukt wird oft auch als „Data Lake“ bezeichnet. Der Zugriff auf die einzelnen Komponenten kann jedoch eine Herausforderung darstellen.

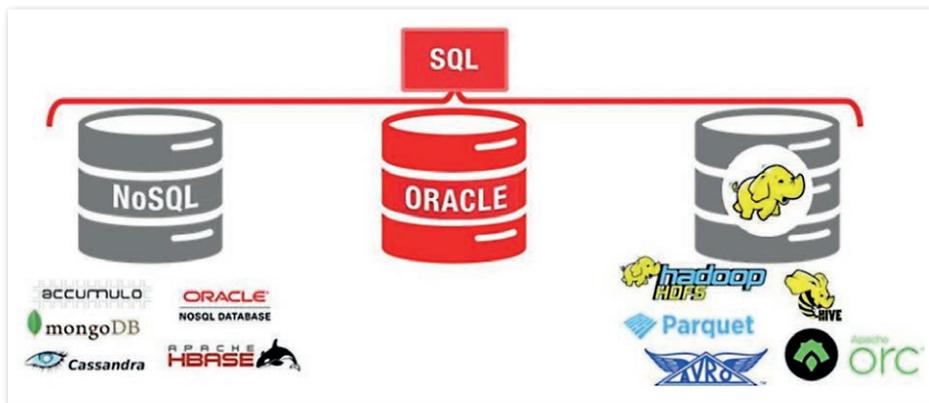


Abbildung 1: SQL kann als omnipotente Zugriffssprache auf die Oracle-Datenbank, NoSQL-Datenbanken und Hadoop genutzt werden – mit Oracle Big Data SQL

Deshalb bietet es sich gerade aufgrund der unterschiedlichen Technologien an, den Zugriff auf alle Komponenten zu zentralisieren. Einfach realisieren lässt sich das etwa mit der Oracle-Datenbank als Herzstück der All-Data-Plattform. Daten aus anderen Datenquellen werden über External Tables verfügbar gemacht.

Mit Oracle Big Data SQL kann dann auch auf Daten in NoSQL-Datenbanken und Hadoop zugegriffen werden. Für Applikationen bleibt damit die Oracle-Datenbank der zentrale Zugriffspunkt, unabhängig davon, wo die Daten abgelegt sind. Auch Security Policies, die die Zugriffsrechte regeln, werden somit auf Daten ausgedehnt, die außerhalb der Oracle-Datenbank liegen (siehe Abbildung 1).

Informationsgewinnung ist kein IT-Entwicklungsproblem, sondern beruht auf einem Verständnis der Daten. Es ist also wichtig, den Schwerpunkt auf eine Definition des Business-Problems und das Deployment der

Tools zur Lösung dieses Problems zu setzen. Generell hat Big Data sehr viel mit Datendemokratie zu tun – eine größere Menge an Daten soll mehr Mitarbeitern zur Verfügung gestellt werden. Die Informationsgewinnung aus Firmendaten ist damit nicht mehr nur den Analysten vorbehalten, sondern soll auch zur Aufgabe der Fachanwender werden.

Mit den neuen Anforderungen an Datenanalyse-Möglichkeiten reichen die klassischen Analyse-Tools nicht mehr aus. Um ihr Fachwissen voll einbringen zu können, benötigen Anwender in den Fachbereichen intuitive Visualisierungs-Tools, mit denen sie neben zentral abgelegten Daten auch lokale Dateien wie Excel-Files in ihre Analysen einbeziehen können.

Data Scientists haben andere Anforderungen an ihre Analyse-Tools als Fachanwender. Zur Kooperation mit Fachanwendern und Entscheidern benötigen sie Visualisierungs-Tools – sowohl in der Discovery-Phase als auch für die eigentlichen Analysen. Sie wollen jedoch auch weiterhin bewährte Sprachen wie R oder Python zur Daten-Analyse nutzen. Hier bieten sich Tools an, die eine Integration mit diesen Sprachen besitzen.

Entscheidet man sich also initial gleich für eine komplette, langfristige Lösung, nimmt man sich die Möglichkeit des Ausprobierens von Methoden und Tools, inklusive der Option des schnellen Scheiterns. Erfolgreiche Analyse-Teams nutzen in der Regel eine Vielfalt an Tools und Techniken, nicht nur in der Discovery-Phase. Die Mischung von Lösungen On-Premise und in der Cloud bietet hier die nötige Flexibilität.

Wenn Analyse-Ergebnisse richtungsweisend sowohl für operationale als auch für strategische Entscheidungen sein sollen, ist es unabdingbar, die Qualität der zu analysierenden Daten sicherzustellen. Entschei-

	„klassisch“		Hosting		Cloud					
Development	🏠	🔵	🔵	🏠	🔵	🔵	🏠	🔵	🔵	...
Customising	🏠	🏠	🏠	🏠	🔵	🔵	🏠	🏠	🏠	...
Installation	🏠	🏠	🏠	🏠	🔵	🔵	🏠	🏠	🔵	...
Hardware	🏠	🏠	🔵	🔵	🔵	🔵	🔵	🔵	🔵	...
Wo?	🏠	🏠	🔵	🔵	🔵	🏠	🔵	🔵	🔵	...
Schnittstellen	🏠	🏠	🏠	🏠	🔵	🔵	🏠	🏠	🏠	...
Management	🏠	🏠	🏠	🏠	🔵	🔵	🏠	🏠	🔵	...

Abbildung 2: Cloud ist nur eine andere Darreichungsform von Informationstechnologie: Cloud Services bieten vom traditionellen Hosting, über die Bereitstellung von fertigen Applikationen bis zur Cloud@Customer sämtliche Abstufungen an (grüne Häuser symbolisieren das Unternehmen selbst, blaue Kreise andere Firmen)

dungen, die auf Daten mit schlechter Datenqualität beruhen, werden in der Regel suboptimal sein.

Um Daten zu analysieren, müssen diese zuerst mithilfe eines Schemas strukturiert werden. Beim relationalen Ansatz wird das Datenschema angewandt, wenn die Daten in die Datenbank geschrieben werden („Schema on Write“). In den meisten Data Warehouses beinhaltet dies die Validierung der Datenqualität und die Integration von Daten aus unterschiedlichen Quellen. Der zugrunde liegende ETL-Prozess (Extract-Transform-Load) muss vor der produktiven Anwendung den normalen Entwicklungszyklus inklusive Testphase durchlaufen.

Beim Big-Data-Ansatz werden die Daten in der Regel erst beim Lesen direkt vor der Analyse strukturiert („Schema in Read“). Dadurch erhält man eine Flexibilität bei der Wahl eines Datenschemas, da dieses erst beim Lesen der Daten angewandt wird. Somit können auch Daten mit niedriger Datenqualität abgespeichert und verarbeitet werden – das Datenschema wird erst bei der Verarbeitung entwickelt. Für unterschiedliche Analysen können somit auch unterschiedliche Schemata angewandt werden. Dieser Ansatz ist ideal, wenn Struktur und Umfang der Daten noch nicht vollständig bekannt sind (Stichpunkt „Data Discovery“).

„Schema in Read“ bedeutet aber auch, dass im Vergleich zum „Schema on Write“-Ansatz ein zusätzlicher Schritt vor jeder Datenanalyse nötig ist. Diese Prozessierungskosten treten also jedes Mal auf, wenn Daten analysiert werden sollen.

Daten, deren Businesswert bereits voll verstanden wurde, deren Qualität bekannt ist und auf die feste Datenschemata angewandt werden sollen, werden deshalb am besten über ETL-Prozesse in einem Data Warehouse abgelegt. Wo dieses Data Warehouse am besten lokalisiert ist – ob in der Cloud oder On-Premise – hängt davon ab, wo die Daten herkommen und welche Anwendungen auf sie zugreifen sollen.

Cloud, Hosting, On-Premise

Cloud Services können als eine andere Darreichungsform von Informations-Technologie verstanden werden, verglichen mit dem klassischen Betrieb auf eigener Hardware im eigenen Rechenzentrum. Es sind alle Abstufungen möglich – vom klassischen Hosting bis zu voll durch den Anbieter gemanagten Cloud Machines, die aber im Rechenzentrum des Unternehmens stehen („Cloud@Customer“).

Cloud Services sind kein Ersatz für die eigene IT oder das eigene Rechenzentrum – sie stellen eine Erweiterung der Möglichkeiten (des Werkzeugkoffers) von IT und Fachbereichen dar. Die Nutzung von Cloud Services bringt einen Gewinn an Flexibilität, da leicht skaliert werden kann, ohne neue Hardware zu kaufen. Oft werden fertige Plattformen in der Cloud angeboten, die als On-Premise-Lösung nicht verfügbar sind und dort vom Unternehmen selbst aus einzelnen Komponenten zusammengestellt werden müssten (siehe Abbildung 2).

Generell sind Cloud Services auch eine gute Lösung für Test-Umgebungen: Es muss keine dedizierte Hardware gekauft werden und es fallen nur Kosten für tatsächlichen Nutzen an. Auch neue Software kann als Cloud Service getestet werden, bevor sie dann als Lizenz oder als Cloud Service gekauft wird. Der lokale Installationsaufwand entfällt oder ist zumindest stark eingeschränkt.

Durch Nutzung von Cloud Services findet eine Kostenverschiebung von Capex (Investitionskosten) in Richtung Opex (Betriebskosten) statt, in vielen Unternehmen ein willkommener Nebeneffekt. Es werden Ressourcen im eigenen Rechenzentrum frei, die für Innovationen genutzt werden können. Wenn Unternehmen eine firmeninterne Cloud aufbauen, über die Cloud Services von der IT für unternehmensinterne Kunden angeboten werden, nennt man dies auch „Private Cloud“. Wenn Service-Provider Kunden aus unterschiedlichen Unternehmen Cloud Services zur Verfügung stellen, wird dies auch als „Public Cloud“ bezeichnet.

Für manche Unternehmen verhindern regulatorische Anforderungen eine Speicherung von Firmendaten in einer Public Cloud. Trotzdem kann die Nutzung von Public-Cloud-Services beispielsweise für Testumgebungen sinnvoll sein.

Ein wichtiger Punkt bei der Überlegung, ob Daten in der Cloud oder On-Premise gespeichert werden sollten, ist die Geschwindigkeit der Datenverbindung. Jeder, der schon einmal über eine langsame Hotelleitung versucht hat, seine E-Mails abzurufen, kennt das Problem der Latenzzeiten aus Erfahrung – teilweise bricht das E-Mail-Programm die Verbindung ab, bevor die Anfrage fertig bearbeitet werden kann.

Der Austausch von Firmendaten über Netzwerke findet jedoch in ganz anderen Dimensionen statt. Unternehmen mit mehreren Standorten, über die Daten konsoli-



Exzellente Baupläne für die Digitale Ökonomie!

Dafür steht PROMATIS als Geschäftsprozess-Spezialist mit mehr als 20 Jahren Erfahrung im Markt. Gepaart mit profundem Oracle Know-how schaffen wir für unsere Kunden die Digitale Transformation:

- Oracle SaaS für ERP, SCM, EPM, CX, HCM
- Oracle E-Business Suite und Hyperion
- Oracle Fusion Middleware (PaaS)
- Internet of Things und Industrie 4.0

Vertrauen Sie unserer Expertise als einer der erfahrensten Oracle Platinum Partner – ausgezeichnet mit dem EMEA Oracle Excellence Award 2016.

PROMATIS



PROMATIS Gruppe
Tel. +49 7243 2179-0
www.promatis.de
Ettlingen/Baden · Hamburg · Berlin
Wien (A) · Zürich (CH) · Denver (USA)

diert werden müssen, haben dieses Problem auch ohne die Nutzung von Cloud Services. Wenn Latenzzeiten ein Problem darstellen, sind dedizierte schnelle Leitungen zwischen Rechenzentren möglich. Für einen initialen Daten-Upload können die Daten auch physikalisch auf Festplatten oder Bändern zum Rechenzentrum des Cloud-Anbieters transportiert werden.

Große Datenmengen werden meist nicht in ihrer Gänze analysiert, sondern es werden Stichproben gezogen und verarbeitet. Dies beschleunigt den Datentransfer und die Analyse. Die Ergebnisse sind dann Schätzungen und können von Berechnung zu Berechnung variieren. Sind die Stichproben groß genug, bieten Näherungslösungen eine gute Repräsentation der echten Werte. Die Verwendung von Stichproben ist für viele Anwendungen ausreichend, aber nicht für alle (für Anomaly Detection etwa sollte immer der gesamte Datensatz analysiert werden).

Zur vollständigen Analyse großer Datensätze sollte generell wenn möglich der Analyse-Algorithmus zu den Daten gebracht werden (etwa durch Analyse mit SQL, Oracle R Enterprise, Big Data SQL, Map:Reduce oder Spark). Müssen die Daten erst per Flatfile-Export aus der Datenquelle extrahiert werden, kann dies einen enormen Zeitfaktor darstellen. Die wichtigsten Punkte bei der Entscheidung, ob eine Lösung in der Cloud oder On-Premise liegen sollte:

- Wo kommen die Daten her, die verarbeitet werden sollen? Sollen Daten konsolidiert werden?

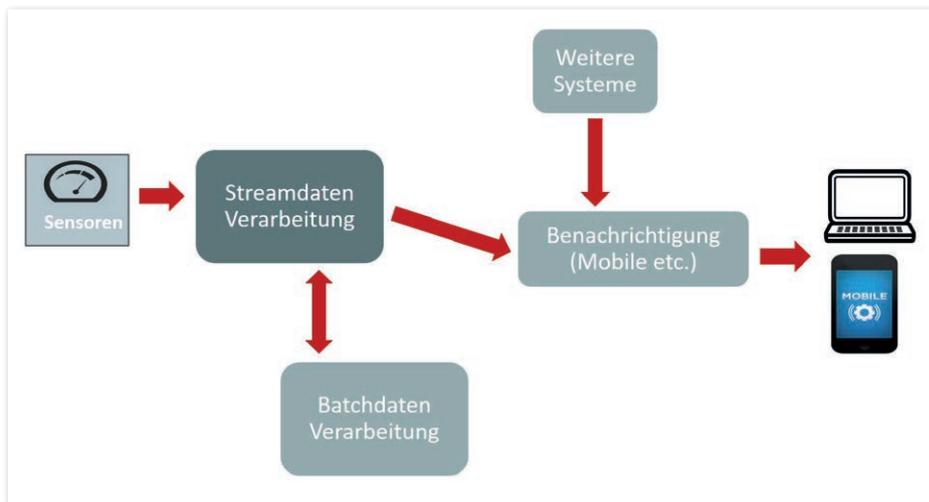


Abbildung 3: Durch die Analyse von Sensordaten können Entscheidungen in nahezu Real-Time getroffen werden. Zeigt die Analyse der Streamingdaten Abweichungen von den vordefinierten Normbedingungen, kann eine sofortige Benachrichtigung durch Push-Notifikationen auf mobile Endgeräte erfolgen. Grenzwerte für die Streamingdaten-Analyse lassen sich aus den Batchdaten errechnen.

- Gibt es Vorschriften oder Policies, die den physikalischen Ort der Daten auf das Rechenzentrum im Unternehmen einschränken?
- Wie flexibel soll die Nutzung der Lösung sein, was den Zeitraum und/oder den Umfang der Nutzung betrifft?
- Wird neue Hardware benötigt? Vor der Anschaffung neuer Hardware lohnt es sich meist, über die Nutzung von Cloud-Services anstelle einer Installation von Software auf eigener Hardware nachzudenken.
- Können Ressourcen, die momentan für Test-Umgebungen verwendet werden, durch Nutzung von Cloud Services freigegeben werden?
- Wie oft müssen welche Mengen an Daten über das Netzwerk geschickt werden?
- Gibt es ein On-Premise-Äquivalent zur optimalen Lösung in der Cloud?

Beispiel: Sensordaten

In nahezu allen technischen Geräten sind mittlerweile Sensoren verbaut. Oft natürlich für den optimalen Betrieb, immer häufiger aber auch, um diese Daten per WLAN oder SIM-Karte zu versenden. Eine zentrale Sammlung der Daten mithilfe eines spezialisierten Cloud Service ist optimal, wenn Analysen sowohl in nahezu Real-Time als auch später in Batches erfolgen sollen. Die Sensordaten von IoT-Prozessen, etwa Telematik-Daten, können so ohne den klassischen Aufwand im Rechenzentrum in Menge, Format und Auftrittshäufigkeit wachsen oder variieren und jeweils optimal verarbeitet werden.

Abbildung 3 zeigt ein Beispiel für eine mögliche Architektur. Sensordaten werden als Datenstream analysiert, um in nahezu Real-Time Entscheidungen zu treffen – etwa um den Ausfall von Maschinen zu verhindern. Werden die Daten sowieso über das Internet konsolidiert, bietet sich hierfür die Nutzung einer fertigen IoT-Lösung in der Cloud an. Benachrichtigungen bei der Abweichung von vordefinierten Normbedingungen (wie Push-Notifikationen auf mobile Endgeräte) können durch Anbindung weiterer Cloud Services sofort verschickt werden. Eine Speicherung der Daten für spätere Batchdaten-Verarbeitung kann sowohl in der Cloud als auch On-Premise erfolgen, je nachdem, welche Systeme später

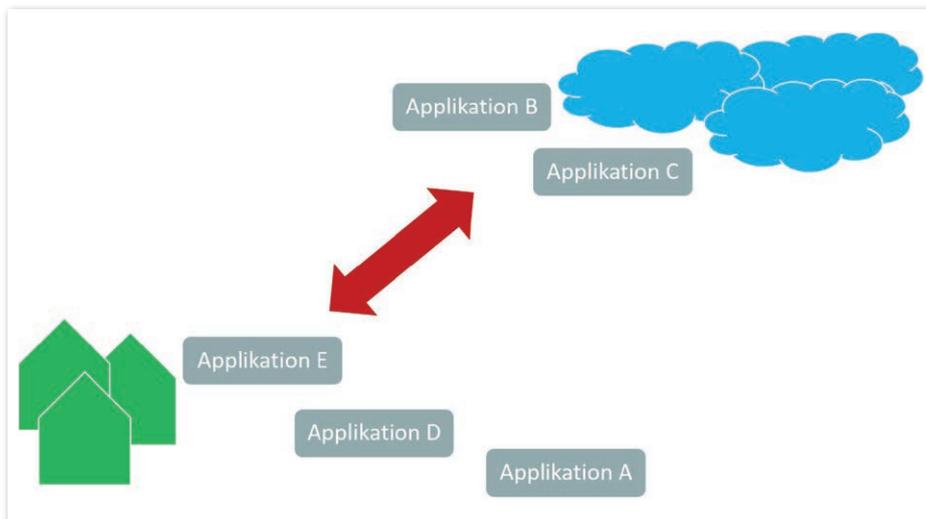


Abbildung 4: Wenn Firmen-Applikationen sowohl On-Premise als auch in der Cloud genutzt werden, findet in jedem Fall ein bidirektionaler Datenfluss statt. Die abschließende Speicherung der Daten kann dann sowohl in der Cloud als auch On-Premise sinnvoll sein.

auf die Daten zugreifen sollen und welche weiteren Daten bei Analysen mit hinzugezogen werden.

Auch wenn die Informationen lokal gesammelt, aber über Standorte hinweg konsolidiert werden sollen, ist die Nutzung von Cloud Services eine sinnvolle Alternative zum Betrieb im eigenen Rechenzentrum. Dies gilt auch, wenn die Daten lokal vorkonsolidiert werden, wie bei den Bosch-Rexroth-Werkstätten. Dort werden die Fahrzeug-Sensordaten zuerst lokal verwendet, aufbereitet und anschließend asynchron zentral verarbeitet; sie stehen so für alle weiteren Verwendungen dort zur Verfügung.

Beispiel: Applikationen-as-a-Service

Immer mehr bestehende Applikationen sind Cloud-ready. Neue Applikationen werden direkt als Cloud-Applikation entwickelt oder anstelle einer Lizenz als Software-as-a-Service (SaaS) erworben. Derartige SaaS-Angebote reichen von CRM-Systemen bis zu Gehaltsabrechnungssystemen oder der Spesen-App, es werden also durchaus unternehmenskritische Prozesse abgebildet.

Die Daten dieser Applikationen haben in der Regel einen hohen Wert für das Unternehmen. Sie werden nicht nur in der Cloud gespeichert, sondern auch transformiert, für Analysen und Berichte aufbereitet und zur Verfügung gestellt. Oft werden auch Daten aus On-Premise-Applikationen und SaaS-Applikationen zur weiteren Nutzung zusammengeführt, es findet also ein Datenfluss in die und aus der Cloud statt (siehe Abbildung 4). Wo die Daten abschließend am sinnvollsten gespeichert sind, hängt von verschiedenen Faktoren ab.

Beispiel: Backup-Möglichkeiten und Archivierung

Viele Unternehmen führen Daten aus On-Premise- und SaaS-Applikationen zur weiteren Nutzung zusammen. Oft werden auch externe Datenquellen hinzugezogen (siehe Abbildung 5). Immer mehr Firmen kaufen zusätzlich Daten von Dritten, um eigene Daten zu ergänzen (Stichwort „Data Enrichment“). Wenn zwischen On-Premise und Cloud sowieso ein Datenfluss erfolgt, bietet es sich an, die konsolidierten Daten sowohl On-Premise als auch in einem Cloud Service vorzuhalten. Beide Datenspeicher können entweder aktiv genutzt werden oder ein Backup wird als Standby-Lösung verwendet. In diesem Fall kann diese Lösung minimal betrieben und bezahlt werden.

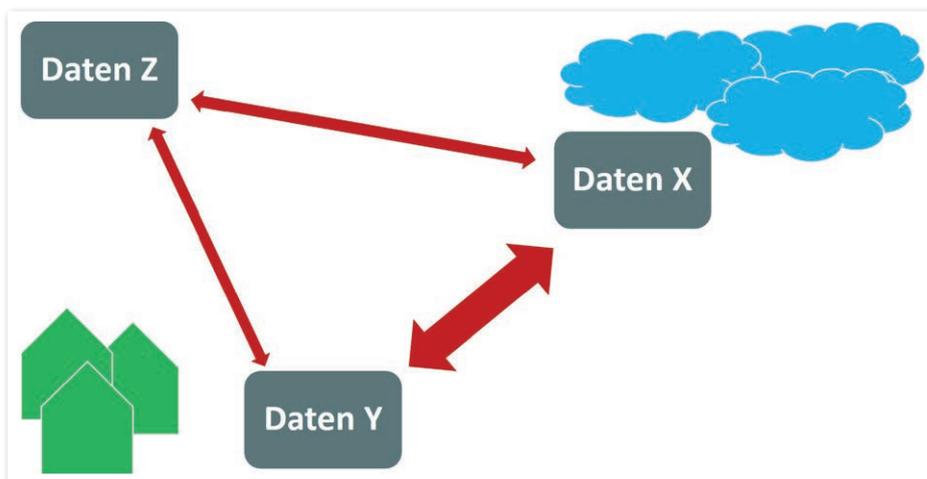


Abbildung 5: In vielen Unternehmen findet bereits ein Datenfluss zwischen On-Premise und Cloud statt. Oft werden auch externe Datenquellen, etwa aus Social Media, hinzugezogen. Hier bietet es sich an, die konsolidierten Daten parallel sowohl On-Premise als auch in einem Cloud Service vorzuhalten.

Eine solche hybride Lösung ist auch sinnvoll, wenn Daten aus verschiedenen Unternehmens-Standorten konsolidiert werden sollen: Die Konsolidierung der Daten findet in der Cloud statt und die gesammelten Daten werden dann in ein Unternehmens-Rechenzentrum gespiegelt.

Auch für eine Archivierung existieren spezialisierte Cloud-Lösungen; diese sind skalierbar und kosteneffektiv. Bewährte Archivierungskonzepte wie RMAN können oft ohne Änderungen am bisherigen Konzept weiterhin genutzt werden.

In manchen Unternehmen verhindern regulatorische Anforderungen ein Backup oder eine Archivierung in der Public Cloud. Hier ist Cloud@Customer eine beachtenswerte Alternative zum Aufbau einer Private Cloud mit eigener Hardware – man erhält die Vorteile von Public-Cloud-Lösungen, aber die Daten verbleiben physikalisch im eigenen Rechenzentrum.

Fazit

Es gibt auch beim Thema „Big/All Data“ keine allumfassende Standard-Lösung, egal ob On-Premise oder in der Cloud. Es muss (wie gewohnt) prozessbezogen entschieden werden, welches Ziel man eigentlich erreichen will. Basierend auf diesen Vorgaben wird dann eine passende Strategie entwickelt, die kontinuierlich angepasst und optimiert werden muss. Vorschriften und interne Policies müssen integriert werden.

Flexibilität ist ein wichtiger Punkt – Technologien entwickeln sich weiter, die Festlegung auf einzelne Technologien kann zu einer suboptimalen IT-Infrastruktur führen

und unnötige Kosten verursachen. Die Nutzung von Cloud Services erweitert hier die Möglichkeiten. Generell ist die Nutzung von Cloud-Diensten immer dann sinnvoll, wenn Daten sowieso an verschiedenen Standorten erzeugt oder vorgehalten werden müssen. Aber auch Backups und Archivierung in der Cloud sind möglich und setzen Ressourcen im eigenen Rechenzentrum frei.

Generell ist das Thema „Big /All Data“ nicht nur ein Thema des richtigen Speicherns und Analysierens der Daten (in der Cloud, On-Premise, mit welcher Technologie etc.), sondern vor allem ein Thema des Umdenkens darüber, welcher Wert in den Daten stecken kann. Dies erfordert einen innovationsfreundlichen und experimentellen Ansatz, in dem nicht nur Datenanalysten, sondern auch Fachanwender kooperativ involviert sind.

Dr. Nadine Schöne
nadine.schoene@oracle.com

Detlef E. Schröder
detlef.e.schroeder@oracle.com



Trinkwasser-Sicherheit mit Predictive Analytics und Oracle

Prof. Thomas Bartz-Beielstein, Steffen Moritz und Jan Strohschein, Technische Hochschule Köln, sowie Dimitri Gross und Ralf Seger, OPITZ CONSULTING GmbH

Verunreinigungen im Wassernetz können weite Teile der Bevölkerung unmittelbar gefährden. Gefahrenpotenziale bestehen dabei nicht nur durch mögliche kriminelle Handlungen und terroristische Anschläge. Auch Betriebsstörungen, Systemfehler und Naturkatastrophen können zu Verunreinigungen führen.

Um die Auswirkungen von unbeabsichtigten und vorsätzlichen Kontaminationen des Trinkwassers so gering wie möglich zu halten, arbeiten Wasserversorger, Forschungsinstitute und private Unternehmen gemeinsam an Schutzkonzepten. Dabei setzen die Versorger zum Beispiel sogenannte „Event

Detection Systems“ ein und installieren Online-Sensorik zur Überwachung der Wasserqualität an verschiedenen Positionen im gesamten Trinkwassernetz. Für die Ermittlung von Anomalien werden meist Verfahren des maschinellen Lernens eingesetzt. Der erste Teil des Artikels gibt einen Einblick in den

Aufbau des Event-Detection-Systems für die Trinkwasserversorgung, während im zweiten Teil aufgezeigt ist, wie sich die Anforderungen an Big Data und Predictive Analytics mit Oracle-Software umsetzen lassen.

Trinkwassernetze stehen unter besonderer Aufmerksamkeit. Sie gehören zu den Ein-

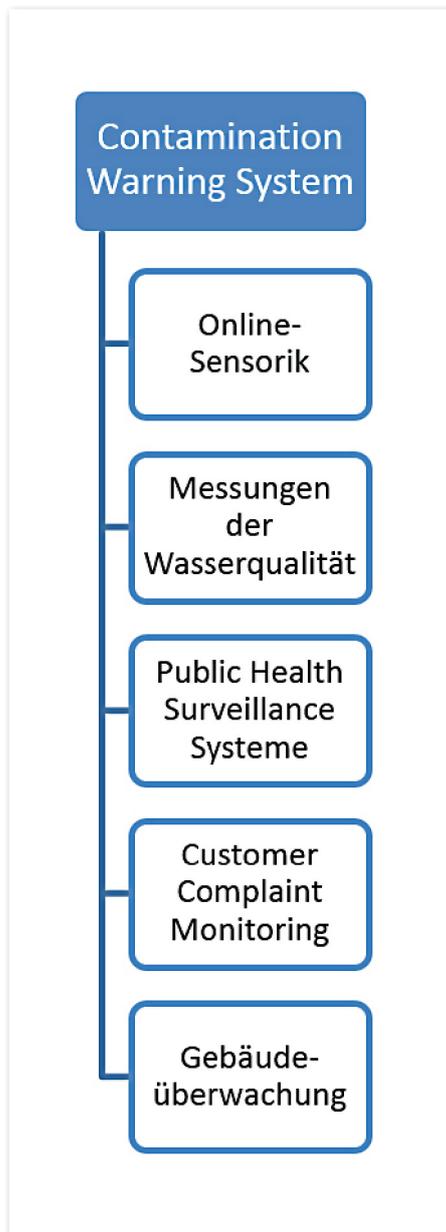


Abbildung 1: Die Bestandteile eines Contamination-Warning-Systems (CWS)

richtungen mit zentraler Bedeutung für das staatliche Gemeinwesen, bei deren Ausfall oder Beeinträchtigung nachhaltig wirkende Versorgungsengpässe, erhebliche Störungen der öffentlichen Sicherheit oder andere dramatische Folgen eintreten. Die öffentliche Wasserversorgung gehört daher neben Sektoren wie Energie und Gesundheit sowie Informationstechnik oder Telekommunikation zu den sogenannten „kritischen Infrastrukturen“ [1].

In aktuellen Forschungsvorhaben arbeiten Wasserversorger, Forschungsinstitute und private Unternehmen gemeinsam daran, die Auswirkungen von unbeabsichtigten und vorsätzlichen Kontaminationen des Trinkwassers so gering wie möglich zu

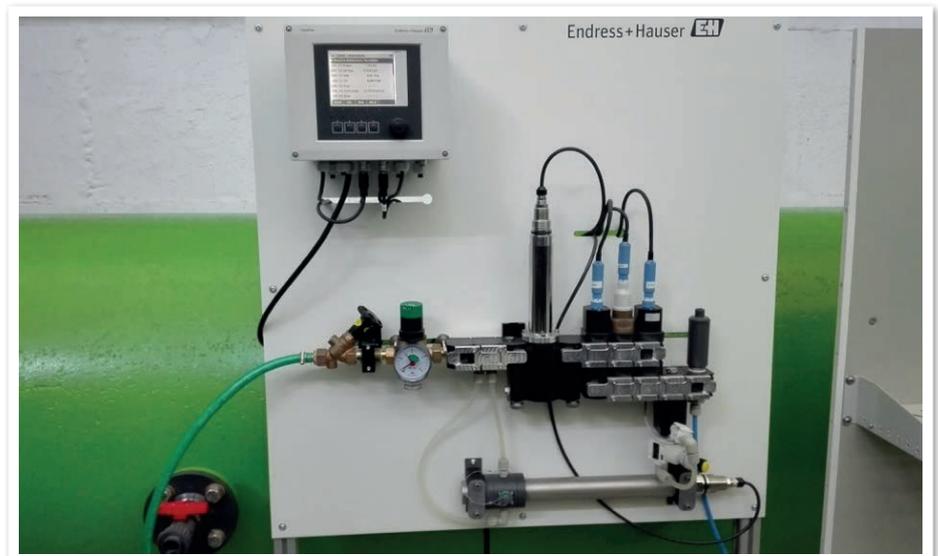


Abbildung 2: Sensorpanel mit Sensoren für Redox-Potenzial, Leitfähigkeit, Chlordioxid, Temperatur, pH-Wert und Trübung

halten. Insbesondere die amerikanische Umweltschutzbehörde EPA nimmt hier eine Vorreiterrolle ein und treibt das Thema in mehreren Forschungsprojekten voran. Auch in Deutschland gibt und gab es bereits mehrere Forschungsprojekte dazu; unter anderem beschäftigt sich die Arbeitsgruppe SPOTSeven der TH Köln im Verbundprojekt „IMProvT“ in Zusammenarbeit mit mehreren Wasserversorgern und dem Sensorhersteller E+H Conducta mit der rechtzeitigen Erkennung von Qualitätsbeeinträchtigungen im Trinkwasser.

Ein vielversprechender Ansatz ist der Einsatz von Event-Detection-Systemen (EDS). Diese analysieren die anfallenden großen Datenvolumina der Wasserqualitäts-Sensoren und sollen Anomalien zeitnah erkennen. Weil die Parameter der Wasserqualität bereits im Normalbetrieb stark schwanken, ist dies keine einfache Aufgabe. Machine-Learning-Konzepte mit Modellen wie neuronalen Netzen oder Support Vector Machines spielen dabei eine wichtige Rolle.

Das Contamination-Warning-System

Um die Auswirkungen von Verunreinigungen so gering wie möglich zu halten, ist eine zügige Einleitung von Gegenmaßnahmen essenziell. Dies setzt voraus, dass die Kontamination bereits wenige Minuten nach deren Auftreten entdeckt wird. Dafür wurde das Konzept des Contamination-Warning-Systems (CWS) entwickelt. Es bezeichnet das Zusammenspiel verschiedener proaktiver Überwachungs- und Kontrolltechnologien [2]. Daten aus verschiedenen Bereichen und

Systemen wie Online-Sensorik zur Messung der Wasserqualität, Kundenbeschwerden, Labormessungen oder Gebäudeüberwachung werden gesammelt und analysiert (siehe Abbildung 1).

Momentane CWS-Ansätze sind allerdings noch sehr aufwändig. Neben den großen Mengen von anfallenden Daten, die verarbeitet werden müssen, ist vor allem die eingesetzte Sensorik teuer und wartungsintensiv. So belaufen sich die Anschaffungskosten für eine einzelne Messstation im Wasserleitungsnetz bereits auf mehrere Tausend Euro. Auf die Online-Sensorik zu verzichten, ist trotzdem nicht ratsam, denn durch die teilweise mehrmals pro Minute durchgeführten Online-Messungen ist es möglich, Beeinträchtigungen der Wasserqualität schon aufzuzeichnen, bevor das Wasser den Kunden erreicht.

Das reine Aufzeichnen der Daten ist allerdings nur eine Seite der Medaille. Zusätzlich ist noch ein Event-Detection-System (EDS) nötig, um die Daten auszuwerten, automatisiert Anomalien zu erkennen und gegebenenfalls Alarm zu schlagen [4]. Da die Parameter bereits im Normalbetrieb stark schwanken, ist dies keineswegs trivial. Auch Änderungen der Betriebsparameter, wie die Menge des abgegebenen Wassers, können zu ähnlichen Mustern führen wie tatsächliche Qualitätsbeeinträchtigungen. Das EDS muss also einerseits große Datenmengen verarbeiten, andererseits aber die Ergebnisse möglichst zeitnah bereitstellen. Damit stellt es den wichtigsten und anspruchsvollsten Bestandteil eines CWS dar.

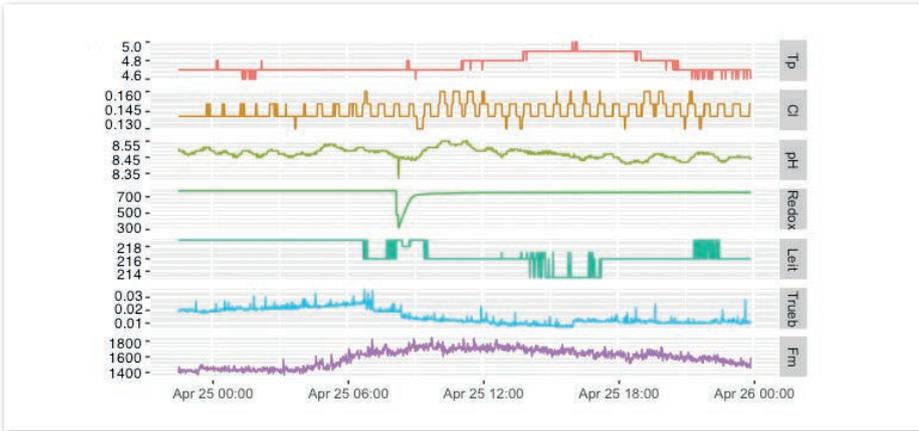


Abbildung 3: Beispielhafte Zeitreihe über 24 Stunden mit Messwerten für Temperatur, Chlordioxid, pH-Wert, Redox-Potenzial, Leitfähigkeit, Trübung und Wasserabgabe-Menge

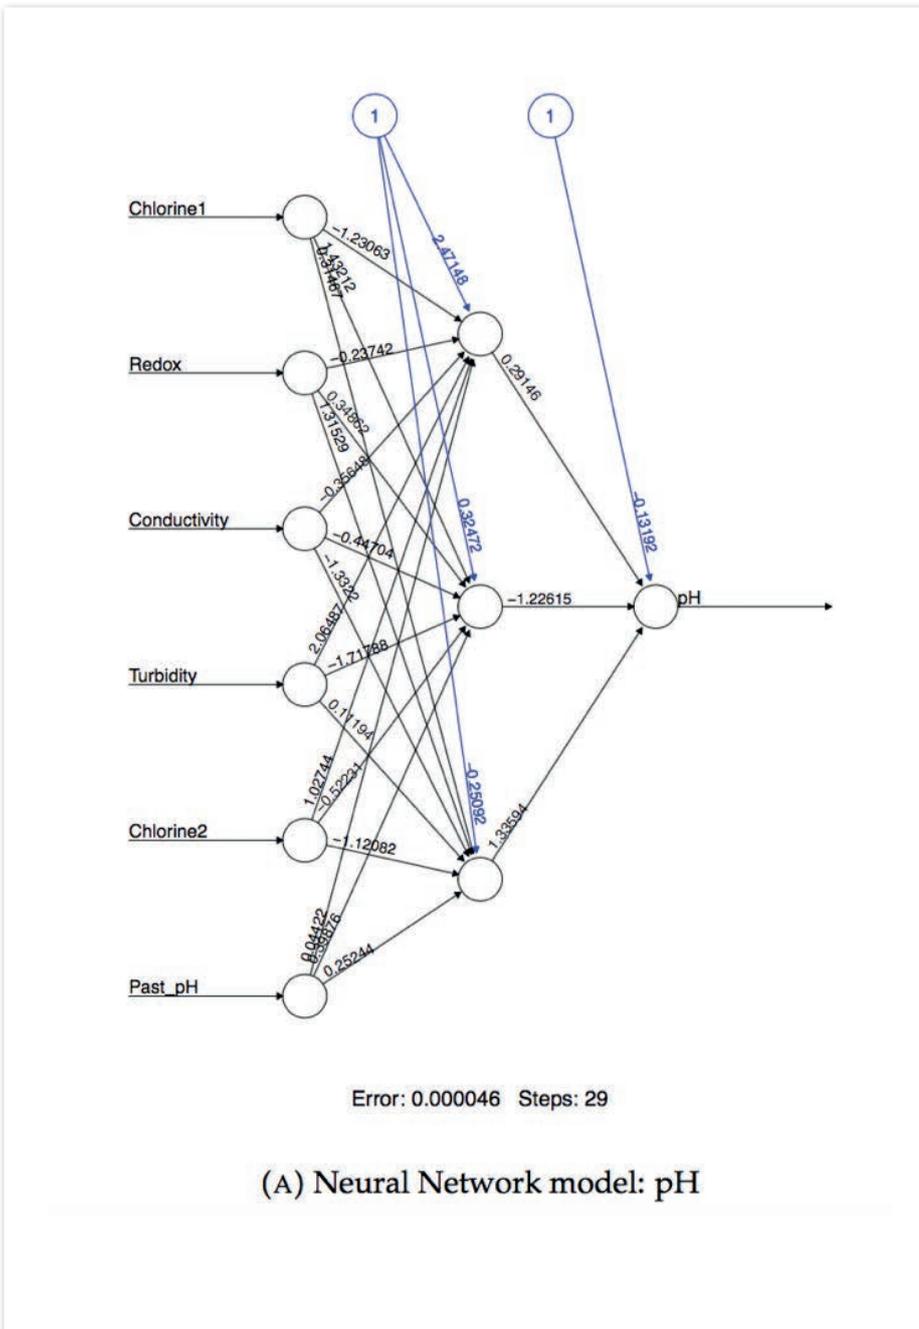


Abbildung 4: Neural Network Model: pH-Wert

Online-Sensorik für die Wasserqualität

Nicht alle Qualitätsparameter, die für eine Analyse sinnvoll sind, können auch wirklich online gemessen werden. Bakterienbelastungen etwa lassen sich nur im Labor oder mit Tests vor Ort zuverlässig ermitteln. Dieser Umstand erschwert die Erkennung von Events, weil die Parameter, die gemessen werden, oftmals nur indirekt auf die Parameter hinweisen, die tatsächlich relevant sind (siehe Abbildung 2).

Zu den typischen Parametern, die für die Detektion von Qualitätsbeeinträchtigungen relevant sind und die auch online gemessen werden können, gehören Temperatur, Chlordioxid, pH-Wert, Leitfähigkeit, Trübung und Redox-Potenzial [3]. Abbildung 3 zeigt einen Ausschnitt aus den Daten einer Messstation.

Grundsätzlich können Anomalien durch die Erhöhung der Sensoren im Netz zuverlässiger und schneller detektiert werden. Da die Sensorpanels allerdings relativ teuer sind und auch regelmäßig gewartet werden müssen, muss im Betrieb ein Kompromiss zwischen Wirtschaftlichkeit und Anzahl der Sensoren eingegangen werden.

Die regelmäßige Wartung und Nachkalibrierung der Sensorik ist hierbei wichtig. Wird sie vernachlässigt, erhöhen verfälschte Messungen die Anzahl der Fehlalarme, die durch das EDS ausgegeben werden. Die Tatsache, dass ein Stromanschluss erforderlich ist und die Datenübertragung sichergestellt sein muss, reduziert die Anzahl möglicher Sensor-Standorte zusätzlich. Im Sensorpanel in Abbildung 2 ist zu sehen, dass die Sensoren keineswegs klein sind und dementsprechend Raum benötigen. Bevorzugte Standorte für die Sensorik sind deshalb Hochbehälter, die einerseits an besonders wichtigen Punkten im Netz stehen und zum anderen auch die für die Infrastruktur benötigten Voraussetzungen mitbringen.

Das Event-Detection-System

Das Event-Detection-System (EDS) dient der Erkennung von Auffälligkeiten in den Daten, die mittels Online-Sensorik aufgenommen wurden. Dazu werden Streaming-Daten verarbeitet [5]. Es ist wichtig, nahezu alle Kontaminationsereignisse zu erkennen und gleichzeitig die Anzahl der Fehlalarme möglichst gering zu halten. Realisiert wird die Detektion von Auffälligkeiten im EDS meist in einem zweistufigen Prozess [4].

Im ersten Schritt wird ein zukünftiger Wasserqualitätswert vorhergesagt. Diese Vorhersage basiert in der Regel auf kurz zu-

vor aufgenommenen Werten. Dafür kommen unterschiedliche Methoden zum Einsatz, etwa modellbasierte Vorhersagen mit neuronalen Netzen oder Support Vector Machines. *Abbildung 4* zeigt beispielhaft ein Modell mit einem neuronalen Netz für den Parameter „pH-Wert“. Input sind die pH-Werte aus der jüngeren Vergangenheit und die Werte weiterer Sensoren. In einem zweiten Schritt werden die berechneten Vorhersagen mit den tatsächlich eintretenden Werten verglichen, sobald diese verfügbar sind. Die Entscheidung, ob eine Anomalie vorliegt, hängt von der Differenz zwischen dem vorhergesagten Wert („Prediction“) und dem tatsächlich eingetretenen Wert („Observation“) ab sowie davon, wie sich diese Differenz über die vergangenen Minuten entwickelt hat. Einzelne Ausreißer in sonst unauffälligen Daten führen hierbei nicht unbedingt direkt zu einem Alarm, denn sie sind oftmals auf Sensorfehler zurückzuführen. Erst wenn mehrere Messwerte hintereinander signifikant von der Prognose abweichen, erfolgt eine Meldung.

Praktische Umsetzung

Die Überwachung der Werte, die das Sensorpanel im CWS erhebt (siehe *Abbildung 2*), ist eine typische Streaming-Problematik. Messdaten werden kontinuierlich im CWS erfasst, versendet und wollen verarbeitet sein. Einzelne Beobachtungen könnten auf ein reales Problem hindeuten, allerdings sind in der Praxis einige Fallstricke zu bewältigen, die bei einem idealisierten Labor-Stream nicht anzutreffen sind:

- Fehler und Ausfall von Sensoren
- Störungen wie Zeitversatz im Sendernetzwerk

Obwohl man schon beim eintreffenden Datenstrom mit Fehlern rechnen muss, wird die gesamte Datenmenge für die Analyse-Pipeline genutzt. Ein persistenter Datenpuffer am Anfang jeder Stream-Verarbeitung stellt sicher, dass die Messdaten nicht verloren gehen, sollte ein technischer Fehler bei der Überwachung auftreten. Eine skalierbare Lösung bietet beispielsweise Apache Kafka (siehe „<https://kafka.apache.org>“). Ein Kafka-Consumer kopiert die eintreffenden Werte in ein Emergency Topic und kann so auf einzelne extreme Sensordaten reagieren.

Im Beispiel in *Abbildung 5* liefert das CWS die Sensordaten für Redox-Potenzial, Leitfähigkeit, Chlordioxid, Temperatur, pH-Wert

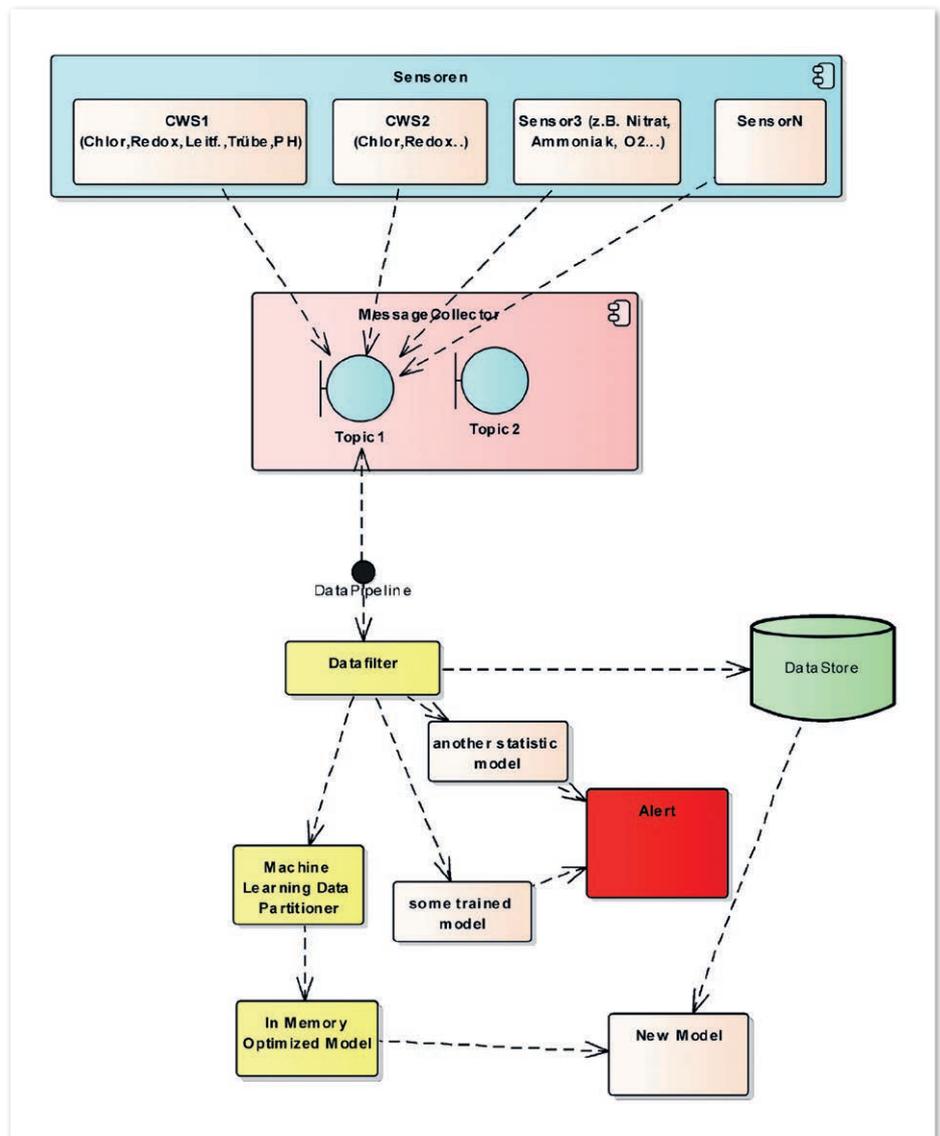


Abbildung 5: Stream-Processing-Architektur mit Einbindung mehrerer CWS-Sensorpanels

und Trübung. Eine Anbindung weiterer Datenquellen ist jederzeit möglich. Die Daten werden entweder aktiv vom Sensor an den MessageCollector gepusht oder die MessageCollector-Komponente holt sich die Daten in bestimmten Zeitintervallen.

Auf Architektur-Ebene entkoppelt das System diese technische Abhängigkeit und liefert der nachfolgenden Verarbeitungs-pipeline (Einstiegspunkt „DataPipeline“) eine neutrale Schnittstelle. Zusätzlich stellt eine hochskalierbare Message Queue wie Apache Kafka die wiederholbare Verarbeitung sicher und verhindert das sogenannte „Information Flooding“.

Message Queues werden schon lange in Enterprise-Anwendungen eingesetzt, um dort unter anderem als Puffer Daten sicher von der Quelle an ihr Ziel zu bringen. Apache Kafka hat außer der herausragenden Performance noch weitere positive Eigenschaften:

Die Daten lassen sich für eine vorkonfigurierbare Zeit zwischenspeichern. Außerdem werden bereits abgeholte Daten nicht automatisch gelöscht. Ein Client kann also jederzeit wieder auf Originaldaten zugreifen. Der Consumer entscheidet, welche Daten er verwenden möchte.

Dem Consumer bieten sich mehrere Optionen an. Eine echte Stream-Verarbeitung kann zum Beispiel mit Apache Storm (siehe „<http://storm.apache.org>“) oder Apache Ignite (siehe „<https://ignite.apache.org>“) erfolgen. Um Modelle zu trainieren, kann er im sogenannten „Micro-Batch-Betrieb“ arbeiten. Im Kontrast zu einem beständigen Datenstrom, der einzelne Tupel an die Topologie sendet, werden beim Micro-Batching mehrere Tupel auf einmal versendet. Die Menge ist meistens über ein Zeitintervall festgelegt. Möglich ist bei manchen Frameworks auch eine fixe Anzahl.

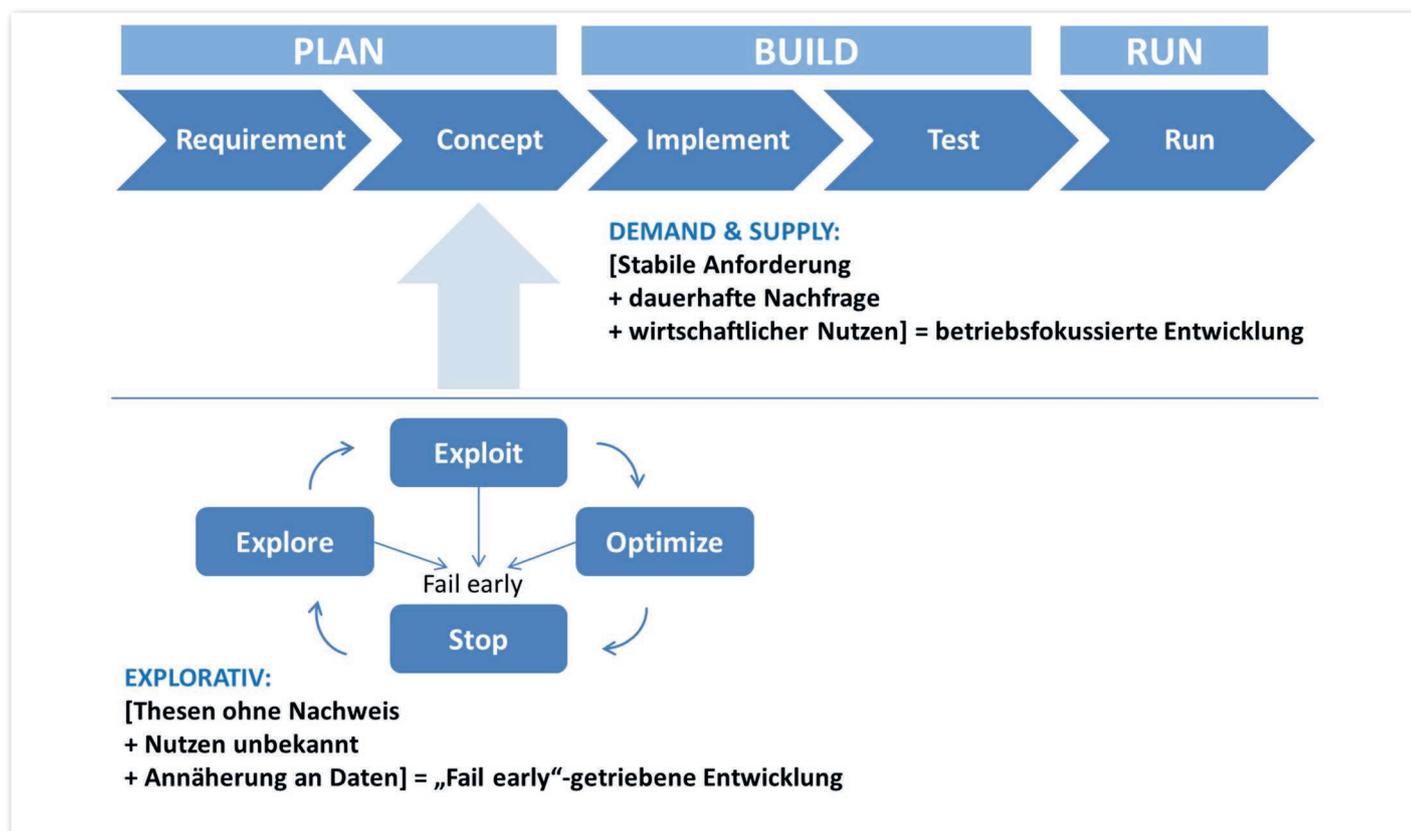


Abbildung 6: „Demand & Supply“ vs. explorative Vorgehensweise

Direkt von Kafka mit Daten betanken lassen sich Alternativen wie das auf Storm aufsetzende Trident (*siehe „<http://storm.apache.org/releases/1.0.1/Trident-tutorial.html>“*), Apache Flink (*siehe „<https://flink.apache.org>“*) oder Apache Spark (*siehe „<http://spark.apache.org>“*). Jedes dieser Frameworks bietet auch eine Integration für Machine Learning Libraries. Im Projekt zur Trinkwasser-Analyse bei der TH Köln kommt das Spark-Streaming zum Einsatz, vor allem aufgrund der größeren Verbreitung und weil die Zeitfenster-Strategien für diesen Use Case ausreichen. In anderen Anwendungen kann Flink mit seinen variablen Zeitfenstern die bessere Wahl darstellen.

Die in *Abbildung 5* dargestellte Verarbeitungspipeline beginnt mit einer Filteroperation. Dieser Filter dient dazu, klare Messfehler aus der Verarbeitungspipeline fernzuhalten. Natürlich sollte dafür bereits Wissen über die Sensorbereiche vorhanden sein. Die ungefilterten Rohdaten fließen deshalb in einen Data Store. Spark unterstützt den schnellen Datentransfer zu einigen NoSQL-Datenbanken wie HBase, Cassandra oder Accumulo.

Der Data Store in *Abbildung 5* liefert die Trainingsdaten für die interaktive Modellierung. Das sogenannte „Supervised Learning“ nimmt einen beträchtlichen zeitlichen Auf-

wand in Anspruch. Allerdings wird durch exploratives Vorgehen außer Referenzmodellen auch Verständnis für Daten generiert. Um mehr Modelle als Kurz- oder Langzeitgedächtnis zu trainieren, sind die Messwerte noch partitioniert. Mit diesen werden „Machine Learner“ trainiert. Die Partitionierung dient nicht nur der schnelleren Performance, sondern hält auch einen Teil der Daten zurück, um die Modellgenauigkeit zu validieren.

Alle so gewonnenen Modelle können zur Alarmierung eingesetzt werden. Aber woran erkennt das System besondere Events, die einen Alarm auslösen können? Welche dieser Events sind relevant? Sensorfehler und fehlende Daten reduzieren die Aussagekraft der gemessenen Daten. Fehlende Messdaten liefern keine valide Aussage über den Zustand des zu beobachtenden Systems. Da immer Zeitfenster betrachtet werden, die eine Zeitreihe von Sensordaten liefern, können einzelne Missing Values ignoriert werden. Ein leeres Zeitfenster ist mit dem Totalausfall eines Sensors gleichzusetzen und zieht als Eskalation eine Reparatur beziehungsweise den Austausch des Sensors nach sich.

Events, die aufgrund ungewöhnlicher Messdaten ausgegeben werden, lassen sich mit den oben erwähnten statistischen Modellen prüfen. Bei klassischen Whitebox-

Modellen (wie „lm“ oder „glm“) lassen sich Konfidenz-Intervalle angeben. Liegen mehrere Messwerte außerhalb dieses Konfidenzbereichs, liegt ein weiterer Alarmierungsfall vor. Bei Black-Box-Modellen (neuronalen Netzen) grenzt man üblicherweise den zulässigen Wertebereich ein. Beobachtungen außerhalb dieser Grenzen werden auf den nächsten Grenzwert normiert [7].

Was noch zu beachten ist

Soweit die Technik. Doch wie sieht es in der Produktion aus? Welche Faktoren können ein Big-Data-Vorhaben zum Scheitern bringen? Das sind Fragen, die viele Unternehmen, die Big Data erproben und in die Produktion überführen möchten, vergessen. Typische Gründe für das Scheitern von Big-Data-Vorhaben sind erfahrungsgemäß:

- Falsche Erwartungen
- Zeitliche Verzögerungen bei der Entscheidungsfindung
- Zu starke Divergenz bei Technologien und vorhandenen Skills

Diese drei Schlüsselaspekte sollten vor dem Start eines Big-Data-Vorhabens geklärt werden. So empfiehlt sich beispielsweise Lean Startup [6] als methodische Vorgehensweise.

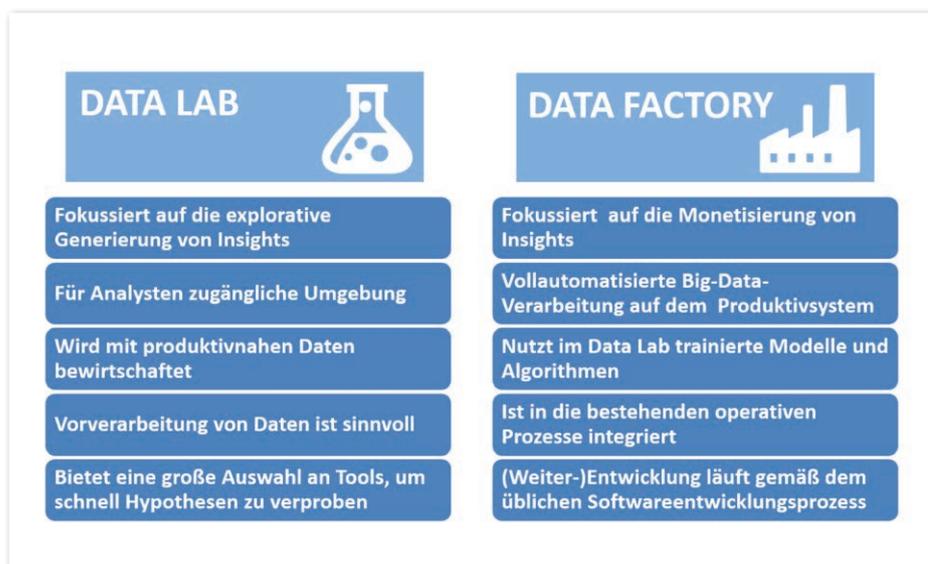


Abbildung 7: Kernprozesse in Data Lab & Data Factory

Es kann beim Management das Bewusstsein dafür schärfen, dass eine Hypothese auch ein negatives Resultat liefern kann.

Zudem ist es wichtig, sich mit organisatorischen Fragen auseinanderzusetzen. Es gibt häufig Unternehmen, die erst angesichts des drohenden Scheiterns eines Pilotprojekts eine organisatorische Anpassung überprüfen und angehen. Wenn das Management erst zu diesem Zeitpunkt feststellt, dass eine etablierte, jedoch rigide Organisationsform (Plan-Build-Run) nicht zu einem hoch agilen Thema wie Big Data passt, kann ein Umschwenken sehr teuer werden.

Rigide Abläufe, lange Zyklen im Anforderungsmanagement und fehlende Möglichkeiten, ein dediziertes Team für Big-Data-Vorhaben zusammenzustellen, lassen ein Projekt scheitern. Letztendlich wären damit also bürokratische Hürden mit zu vielen Schnittstellen der wesentliche Grund. Nur ein Schritt in Richtung einer virtuellen Organisation kann hier bereits Abhilfe schaffen. Die Aufbau-Organisation ist dabei ein individuelles Thema und richtet sich immer an die Gesamtstruktur des Unternehmens. Auch das Gewicht des Big-Data-Vorhabens für die Gesamtunternehmung spielt hier eine Rolle. Ein weiterer wichtiger Punkt sind die vorhandenen Skills und das Know-how zu neuen Technologien im Unternehmen. Der Prozess für den Skill-Aufbau kann parallel mit den organisatorischen Maßnahmen stattfinden. Ein weiterer Faktor, der den explorativen Prozess der Hypothesen-Erprobung beschleunigen kann, ist der Einsatz einer Big-Data-Distribution, die auf einer passenden Hardware läuft. Man stelle sich die Datenbe-

wirtschaftung als zwei in sich greifende Prozesse vor. Der erste Prozess, der sich mit der explorativen Überprüfung von Hypothesen beschäftigt (siehe Abbildung 6), wird in der Praxis oft als „Data Lab“ bezeichnet. Dementsprechend definiert der zweite Prozess einen stabilen Produktivbetrieb und wird üblicherweise als „Data Factory“ bezeichnet (siehe Abbildung 7).

Ein Engineered System, in dem Hardware und Software kombiniert sind, bietet Oracle mit seiner Big Data Appliance an. Auf dieser mächtigen Hardware läuft Cloudera EDH mit den dazugehörigen Frameworks. Das System ermöglicht zum einen die prototypische Umsetzung und stellt zum anderen den Produktivbetrieb im Rahmen einer Data Factory sicher. Apache Zeppelin, das in der Cloudera EDH mitgeliefert wird, ermöglicht eine explorative Erprobung von Hypothesen, was wiederum gut zum Data-Lab-Konzept passt. In diesem Szenario arbeiten die Data Scientists an der Erprobung mathematischer Verfahren, während ein Team aus Software-Entwicklern und Integratoren die bereits validierten Hypothesen in die produktive Datenbewirtschaftung überführt.

Fazit

Neue Entwicklungen im Bereich der Sensortechnik, des High Performance Computing und der Daten-Analyse (Big Data, Deep Learning) ermöglichen Lösungen in Bereichen, die noch vor wenigen Jahren aufgrund von fehlenden Daten oder wegen der großen Berechnungskomplexität undenkbar gewesen wären. Die in diesem Artikel beschriebene Online-Trinkwasserüberwachung, die im

Verbundprojekt „IMProvT“ der TH Köln von der Arbeitsgruppe SPOTSeven (siehe „www.spotseven.de“) entwickelt wird, stellt ein prominentes Beispiel dar.

Die verschiedenen Produkte der Apache Software Foundation erlauben eine skalierbare und ausfallsichere Verarbeitung von Big Data und insbesondere von Streaming-Daten. In Kombination mit neuen, erschwinglichen Cloud-Angeboten für die hochperformante Datenverarbeitung und -speicherung werden solche Projekte auch für große Datenmengen wirtschaftlich sinnvoll – für sensible Daten durch eine Oracle Cloud Machine sogar On-Premise im eigenen Datencenter. Die geringen Kosten erlauben es agilen Teams, neue Ansätze auszuprobieren, explorativ die wirtschaftlichen Möglichkeiten eines Vorhabens auszuloten und bei den Mitarbeitern wertvolle Fähigkeiten aufzubauen.

Literatur

- [1] Bundesministerium des Innern, Nationale Strategie zum Schutz kritischer Infrastrukturen, 2009
- [2] Roberson, J. Alan, Morley, Kevin M., Contamination Warning Systems for Water: An Approach for Providing Actionable Information to Decision-Makers, American Water Works Association, 2005
- [3] Storey, Michael V., van der Gaag, Bram, Burns, Brendan P., Advances in On-line Drinking Water Quality monitoring and early warning systems, Water Research 45.2, 2011 (Seite 741 – 747)
- [4] Murray, R., et al., Water Quality Event Detection Systems for Drinking Water Contamination Warning Systems – Development, Testing and Application of CANARY, 2010
- [5] Bartz-Beielstein, T., Experimental Algorithmics Applied to On-line Machine Learning, in Papa, G. and Mernik, M., Bioinspired Optimization Methods and their Applications, 2016 (Seite 94 – 104)
- [6] Ries, E., The Lean Startup: How Today's Entrepreneurs Use Continuous Innovation to Create Radically Successful Businesses. Crown Publishing, 2014
- [7] Klein, B. D., Rossin, D. F., A Preliminary Analysis of Data Quality in Neural Networks, 1997

Dimitri Gross
dimitri.gross@opitz-consulting.com

verbesserter Arbeitsweisen müssen schnell und unabhängig von den Release-Zyklen der Backends verfolgt werden können.

Seitens der Software-Architektur ist die lose Kopplung von Front- zu Backend ein entscheidender Faktor. Alte Ideen werden wieder modern! Die Frontend-Komponenten entkoppeln sich deswegen durch eine spezifische Frontend-Service-Schicht von der Geschäftslogik der Backend-Komponenten, um den unterschiedlichen Veränderungs- und Entwicklungsgeschwindigkeiten gerecht zu werden.

Zurück zum eigentlichen Beispiel. Die Veränderung der Mensch-Maschine-Interaktion wurde über Location-based und Context-aware Apps demonstriert, um ein Gefühl für die potenzielle Veränderung der Arbeitsweise auf dem Shopfloor zu vermitteln. Wichtig ist, dass das Erleben haptisch ist. Die Führungskräfte sollen dies durch eine User Journey auf dem Shopfloor selbst erleben können.

Die Grundidee ist recht einfach: Der Werker trägt einen passiven und personalisierten Sender zur genauen Lokalisierung und Identifikation seiner Position. Er taucht in die Maschinenwelt ein und wird zum Akteur in der Sphäre des Internet of Things. Das hört sich erschreckender an, als es ist. Jeder von uns trägt bereits jetzt ein Smartphone mit GPS-Sender mit sich herum. Wo ist der Unterschied? Im Proof of Concept wurde ein passiver Ultra-Wide-Band-Ansatz mit sechs Messstationen gewählt, um auf etwa dreißig Zentimeter genau lokalisieren zu können. *Abbildung 1* zeigt in einem Überblick den Lageplan des Showcases mit der Nachbildung eines Werks.

Es wurde eine sogenannte „User Journey“ realisiert, um an verschiedenen Stationen die Mensch-Maschine-Interaktion zu zeigen. Die Reise beginnt mit dem Parken des Autos. Die Lokalisierung meldet sich automatisch beim Erreichen der Parkzone, ein Algorithmus weist dem Mitarbeiter den Parkplatz zu und das System erkennt zudem über das Matching der Lokalisierungsdaten, ob er am richtigen Parkplatz parkt. Anschließend betritt er das Werk und die Zeiterfassung wird automatisch ausgelöst.

Nun meldet sich das System bei Events wie zum Beispiel einem Zonenübergang per Benachrichtigung. Ein Klick auf die Nachricht – und die spezielle App für den Typ an Nachricht öffnet sich und zeigt die Information an. Im nächsten Schritt zieht der Werker seine Schutzkleidung für den Shopfloor an. Eine Bilderkennung analysiert den Wer-

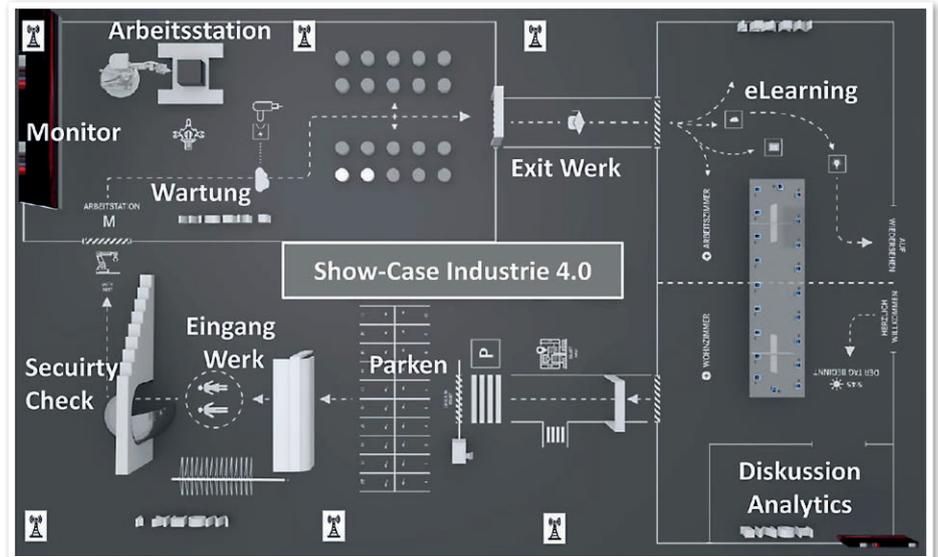


Abbildung 1: Showcase in der Übersicht

ker und prüft das Tragen der notwendigen Schutzkleidung. Von hier aus geht er in die Produktionshalle.

Ein weiterer Arbeitsschritt ist das Arbeiten an einem Motor mit einem Akku-Schrauber (siehe *Abbildung 2*). Der Werker betritt die Arbeitsfläche des Centrick, einer ergonomischen Handhabungshilfe, die Werkstücke so dreht, dass ein Arbeiten rückenschonend ohne Kraftaufwand möglich ist. Über die angesprochene Lokalisierung erkennt der Centrick den Mitarbeiter und nutzt dessen persönliche Daten, um die Arbeitsposition nach Arbeitsauftrag und Größe des Mitarbeiters automatisch einzustellen. Wesentlich ist hier, dass der Centrick mithilfe von Industrie-4.0-Technologien in das Gesamt-Szenario eingebunden ist und damit zu einer intelligenten Maschine wird.

Währenddessen werden alle Bewegungen und Tätigkeiten der Personen auf einem Monitor angezeigt, um ein Abbild des Shopfloors zu erhalten. Ein weiterer demonstrierter Arbeitsschritt ist die Behebung eines Werkzeug-Problems. Hierzu wurde eine HoloLens genutzt, die das Werkstück erkennt und eine Augmented-Reality-Sicht auf das Werkstück legt. Über Handbewegungen kann die entsprechende Dokumentation aufgerufen werden.

In der virtuellen Realität ist alles einfach da, wo es gebraucht wird, oder der Werker befragt via Skype seine Kollegen in einem anderen Werk und man schaut gemeinsam durch die HoloLens auf das defekte Werkstück. In Realtime werden die Hilfestellungen der Kollegen nutzbar. Der virtuell anwesende Kollege kann beispielsweise auf der Maschine Pfeile einzeichnen, um die

Position fehlerhafter Teile zu markieren. Die virtuelle Umgebung ermöglicht eine viel wirkungsvollere Hilfe als die heutigen, rein verbalen Beschreibungen über das Telefon. Die Architektur der Implementierung ist in *Abbildung 3* in einer groben Form dargestellt.

Die Frontend-Apps sind mit einer Angular2-Oberfläche realisiert, wobei jeder Prozess-Schritt beziehungsweise jede Aktivität eine eigene App ist. Auf die Nutzung einer großen Single-Page-App wurde hier verzichtet, um die Komplexität zu verringern und eine unabhängige Veränderung zu ermöglichen. Dies war in Verlauf des Projekts eine gute Entscheidung. Die Gesamtlösung wurde mit einem Lean-Startup-Ansatz erstellt, wobei eine Vielzahl von teilweise im Detail gravierenden Änderungen nötig war. Somit konnten Neuerungen unabhängig von anderen Frontends eingebaut werden.

Die Delivery-Schicht ist mit einer Backend-for-Frontend-Architektur (BFF) implementiert. Sie hatte, wie in *Abbildung 2* ersichtlich, vier BFFs, um die unterschiedlichen Objektmodelle und APIs zu unterstützen. Der Analytics-Teil erfolgte über eine Streaming-Lösung mit einem Big-Data-Ansatz sowie entsprechenden Komponenten zur Visualisierung von Statistiken und Bewegungsmustern.

Die Ortung der Mitarbeiter eröffnet interessante Perspektiven: Hindernisse, die den Werker zu Umwegen zwingen oder ihn zu riskanten Abkürzungen verleiten, werden sichtbar und können aus dem Weg geräumt werden. Die Fluchtkorridore und Notausgänge können besser geplant werden, wenn bekannt ist, wo sich die Mitarbeiter tatsäch-

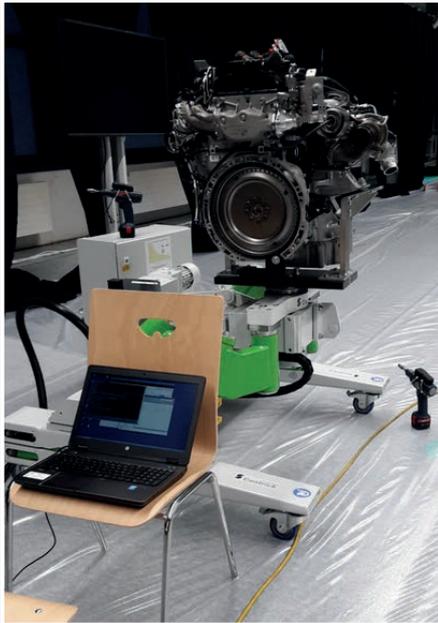


Abbildung 2: Der Montageplatz (Quelle: Schreiber Metalltechnik und Maschinenbau GmbH)

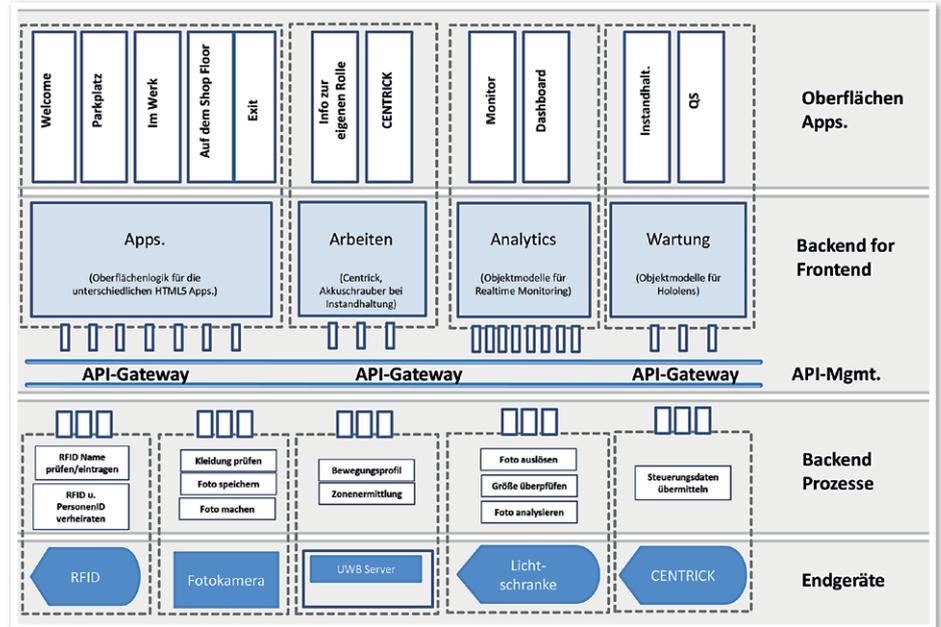


Abbildung 3: Die Komponenten-Architektur

lich aufhalten. Wenn doch einmal ein Unfall passiert, wird es leichter, vermisste Mitarbeiter wiederaufzufinden. Die gleiche Idee wird auch im Wintersport bei der Bergung von Lawinenopfern verfolgt.

Das Beispiel zeigt auch, wie unabdingbar es ist, die Mitarbeiter bei der Entwicklung und Einführung der neuen Technologien einzubeziehen. Es ist wichtig, auf die Ängste vor einer Überwachung einzugehen. Ein guter Ansatz ist, deutlich zu machen, dass die Ortung Grenzen hat und wo die Grenzen der Ortung liegen. Bei der gewählten Technik hörte die Geo-Lokalisierung bereits zwei, drei Meter neben dem Messstand auf.

Über diesen recht umfangreichen Proof of Concept konnten die Führungskräfte sehen, wie es sich als Werker auf einem zu-

künftigen Shopfloor anfühlt, zu einem Teil des Ganzen zu werden. Die Philosophie der Werker-Steuerung verändert sich grundlegend. War dies in der Vergangenheit geprägt durch starre Prozesse, so verändert sich die Arbeitsweise in Richtung eines Event-orientierten Ansatzes mit einer Task-Liste für Eskalationen und Meldungen.

Der Workflow-Ansatz mit vordefinierten Aktivitäten, der die Arbeit am Fließband so monoton macht, gehört der Vergangenheit an. Die Zukunft gehört dem intelligenten Mitarbeiter, der abhängig von der jeweiligen Situation selbstständig Entscheidungen trifft. Aus einem Eintrag der Task-Liste öffnet das System durch Interpretation des Kontextes automatisch die entsprechende App, um die Aufgaben zu lösen. Das Konzept ähnelt

der Datei-Präferenz von Betriebssystemen. Somit kennt die App die Meldungstypen und die Apps, die diese verarbeiten können. Gleichzeitig entfällt partiell die Notwendigkeit umfangreicher Experten-Oberflächen. Beim Design der Oberflächen fokussiert man sich auf transparente, selbsterklärende Oberflächen für bestimmte Arbeitsschritte. Und das große Ziel vieler Hersteller rückt in greifbare Nähe: „Losgröße 1“.

Durch die IT-Unterstützung verringert sich die Notwendigkeit, die Produktionsprozesse soweit zu standardisieren, bis jeder Handgriff sitzt. Der Bildschirm oder die HoloLens zeigen, was die Besonderheiten des nächsten Werkstücks sind. Das ermöglicht mehr Flexibilität, bis hin zur kostengünstigen und effizienten Produktion von individuell unterschiedlichen Werkstücken am Fließband.

Fazit

Zum Abschluss noch ein Blick hinter die Kulissen des Showcases (siehe Abbildung 4). Die letzte Gruppe der Führungskräfte geht durch den Parcours und eine gewisse Anspannung beim Umsetzungsteam ist spürbar. Beim abschließenden Review mit den beteiligten Führungskräften zogen diese ein sehr positives Fazit. Überraschende Möglichkeiten wurden vermittelt, ein haptisches Erleben eines Zusammenwachsens von Mensch und Maschine wurde verstanden und eine Vielzahl an Ideen und Optimierungsansätze geäußert.



Abbildung 4: Ein reibungsloser, störungsfreier Produktionstag auf den Shopfloor im Show-Room

Rolf Scheuch
rolf.scheuch@doag.org



Mobilier Performance Warehouse

Paolo Kreth, die Mobiliar

Die Schweizer Versicherung „die Mobiliar“ hat aus Performance-Daten (AWR, ASH) ein Performance Data Warehouse aufgebaut. Der Bedarf entstand aus einer bevorstehenden Migration aller Oracle-Datenbanken auf eine neue Server-Plattform. Um die Daten wurden verschiedene Apex-Applikationen zur grafischen Auswertung erstellt sowie über Grid Control Reports und Benachrichtigungen eingerichtet.

Es ist in der Mobiliar heute möglich, Trends zu erstellen, Ausreißer aller Datenbanken automatisch zu erkennen, Tuning-Maßnahmen einzuleiten und Auswertungen über die Qualität der Applikationen zu erstellen. AWR, ASH, Apex und Grid Control spielen seither in einem Orchester und die DBAs können anhand des gesamten Klangspektrums gezielt und proaktiv intervenieren, noch bevor es zu Problemen kommt.

Ausgangslage

Im Jahr 2013 hat die Mobiliar entschieden, die rund 400 bestehenden Oracle-Instanzen zu migrieren. Ziel war, von zwei IBM P595, auf denen circa 40 LPARs definiert waren, auf sieben physische, nicht virtualisierte Server zu migrieren. Die alte Plattform wurde Ende 2008 in Betrieb genommen. Seither ist die Anzahl der Applikationen und der Datenbanken in der Mobiliar stark gestiegen.

Nach so vielen Jahren stellte das eine große Herausforderung dar. Der Bedarf, dem Management transparente Antworten zu geben, war enorm. Hier einige Beispielfragen, die man sich vor der Migration stellte:

- Reichen die sieben Blades überhaupt aus? Oder sind wir sogar überdimensioniert?
- Wie kann man die Datenbanken optimal neu verteilen?

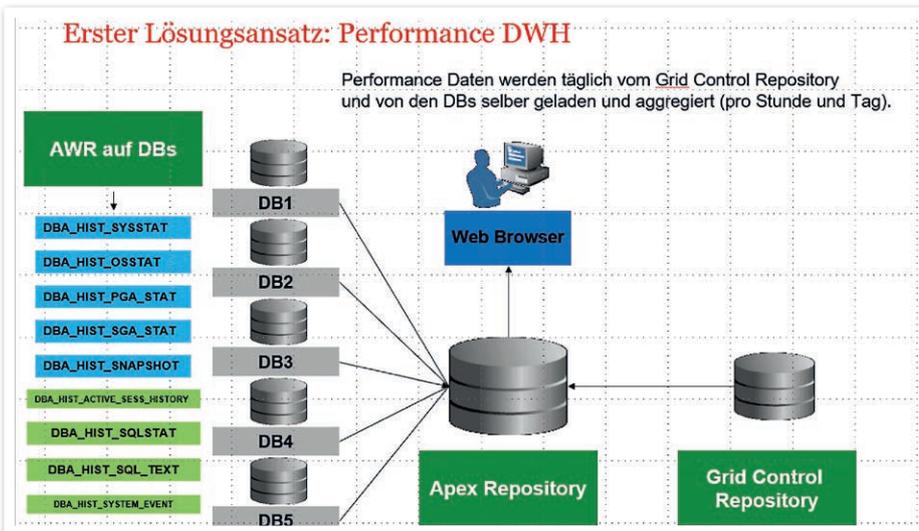


Abbildung 1: Datensammlung

- Stören sich die Datenbanken gegenseitig?
- Kann die gesamte Last in einer nicht virtualisierten Umgebung abgefangen werden?

Die Schwierigkeit bestand nicht nur darin, die technischen Antworten zu liefern, sondern sie in einem Format darzustellen, das für einen Team-, Abteilungs- und Bereichsverantwortlichen verständlich war.

Welche Werkzeuge zur Verfügung standen

In der Mobiliar sind die Oracle Enterprise Edition und der Oracle Enterprise Manager mit verschiedenen Packs im Einsatz. Daten werden regelmäßig im AWR gespeichert und stehen dort für Analysen zur Verfügung. Grid Control hat eine grafische Oberfläche, mit der sich die Performance-Daten anzeigen lassen. Aber es stellte sich schnell die Einschränkung für eine Gesamtauswertung aller Datenbanken heraus: Grid Control ist datenbankorientiert. Die Performance-Daten einer einzelnen Datenbank lassen sich mit Grid Control einfach anzeigen und auswerten. Die Aggregationen der Daten dagegen, etwa über mehrere Datenbanken auf einem Server, sind nicht möglich. Das war genau die Herausforderung, um die optimale Verteilung der Datenbanken auf den physischen Servern zu finden.

Deshalb überlegte man sich, die im AWR der einzelnen Datenbanken enthaltenen Performance-Daten in einer Datenbank zu speichern und diese dann mit Apex aggregiert auszuwerten. Es wurden Daten aus gezielten Performance Views identifiziert und gesammelt (siehe Abbildung 1 in blau) und im zweiten Schritt weitere Performance Views hinzugefügt (grün). So entstand nach und nach ein Performance Warehouse.

Heute sind mehr als 150 AWR-Views im Performance Warehouse aggregiert. Zudem werden mehr als 100 Data-Dictionary-Tabellen und verschiedene Session-Informationen geladen und ausgewertet. Die Aggregationen über die Performance-Daten sind grafisch auswertbar. Als Beispiel in Abbildung 2 ist die Auswirkung der Monatsverarbeitung auf der Risk-Management-Datenbank (RICO, rot) gegenüber anderen Datenbanken dargestellt. In diesem Fall wurde die System-Statistik „Session Logical Read“ verwendet, um die Auswertung durchzuführen. Analog lassen sich auch andere System-Statistiken wie Physical Reads, Physical Writes, CPU-Verbrauch etc., die aus der Performance View „DBA_HIST_SYSSTAT“ stammen, auswählen. Als Resultat wird ersichtlich, dass die RICO-Verar-

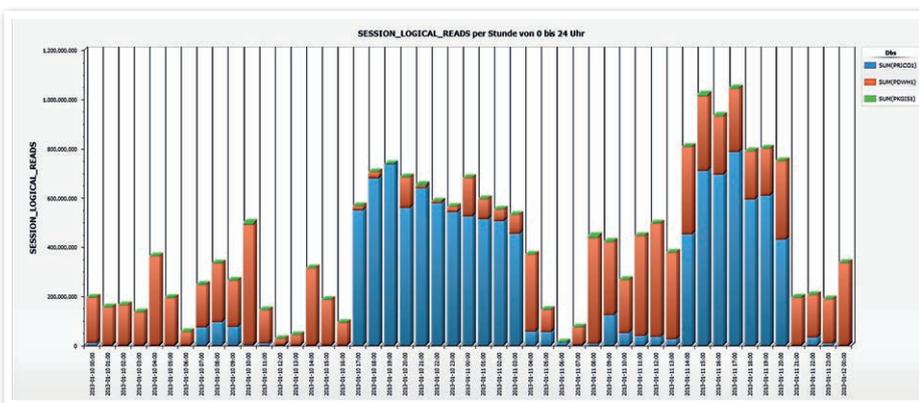


Abbildung 2: Die Monatsverarbeitung RICO stört andere Datenbanken nur gering

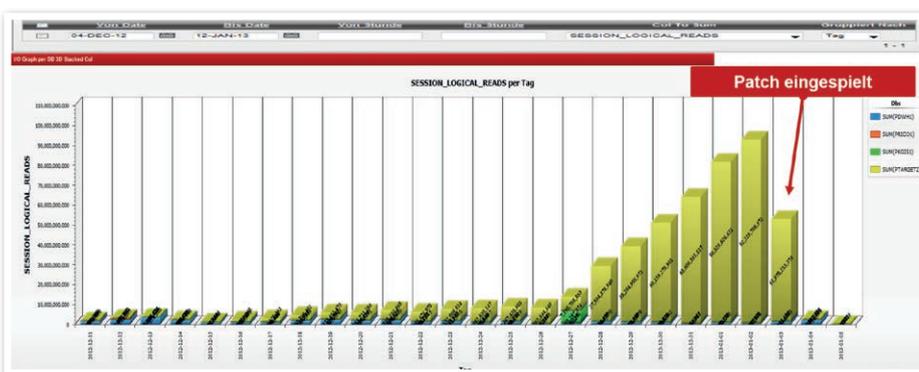


Abbildung 3: Eine Datenbank spielt verrückt

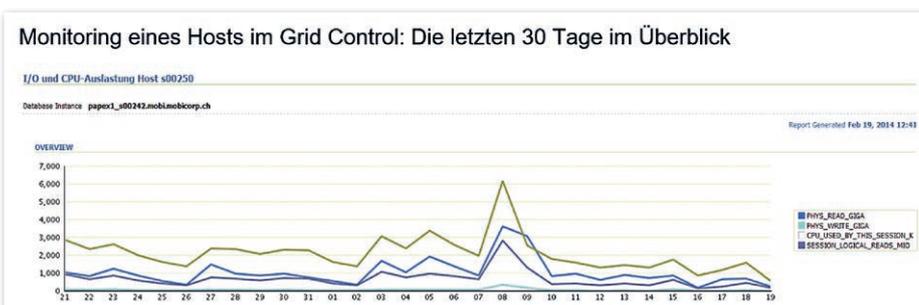


Abbildung 4: CPU- und I/O-Verbrauch auf einem Server über 30 Tage

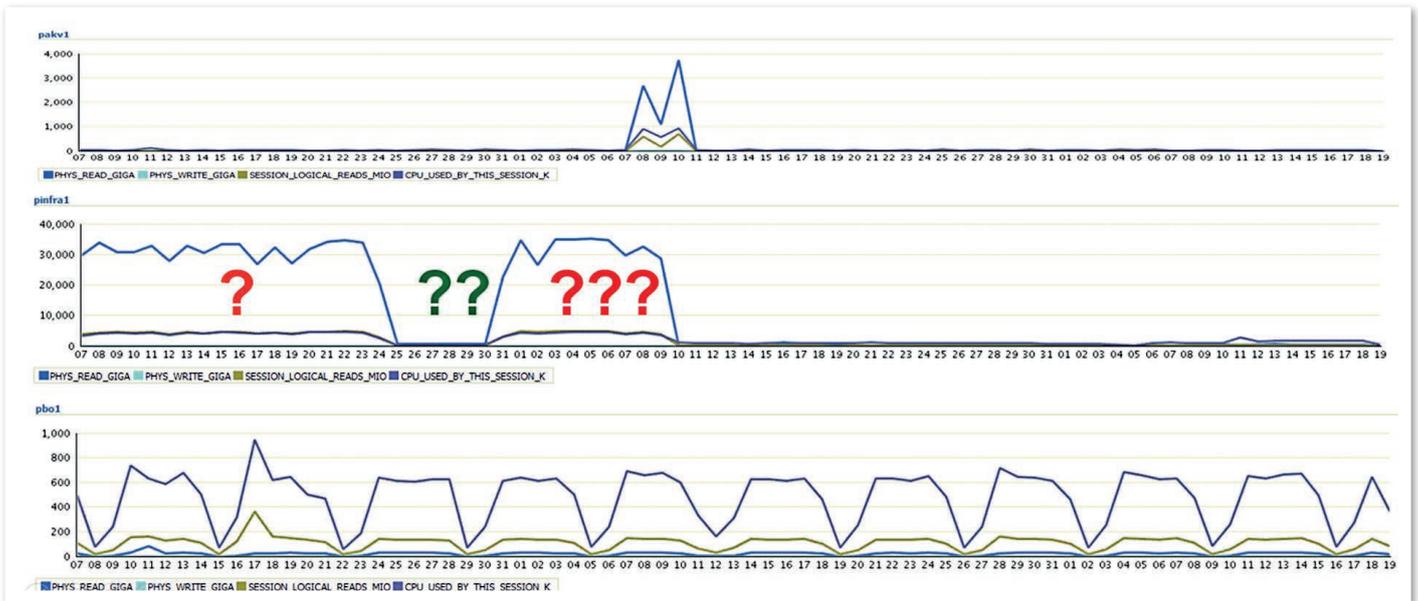


Abbildung 5: CPU- und I/O-Verbrauch auf einer Datenbank über 75 Tage. Ausreißer werden automatisch identifiziert.

beitung in Randzeiten stattfindet, während auf den anderen Datenbanken nur geringe Belastung herrscht. Zwar gibt es gegen Ende der Verarbeitung eine Überlappung, aber die Gesamtlast ist viel geringer als die Kapazität der Maschine. Die maximale Kapazität ist aus einem Benchmark bekannt, der auf den Servern vor Einführung ausgeführt wurde.

Der Appetit kommt mit dem Essen

Da die Daten zur Verfügung stehen, sind jetzt Auswertungen über verschiedene Zeiten möglich. Als Beispiel die Auswirkung eines Bugs auf einer 8 GB großen Datenbank

(siehe Abbildung 3). Die Datenbank verursachte über die Jahreswende 2013 mehr als 100 Mio. Session Logical Reads pro Tag. Zum Vergleich war die Summe der Session Logical Reads der drei größten Datenbanken der Mobiliar in der gleichen Zeit unter 12 Mio. Die Ursache war ein Bug in der Applikation, der schließlich mit einem Patch behoben wurde.

Im Nachhinein ist man immer schlauer

Genau bei diesem Fall wurde festgestellt, dass man viel früher hätte intervenieren können. Wenn man die Steigerung der Session

Logical Reads betrachtet, ist zu sehen, dass an einem gewissen Zeitpunkt etwas Außerordentliches passiert. Da man aber nicht jeden Tag Auswertungen auf allen Umgebungen macht, wurde diese Information nicht rechtzeitig wahrgenommen. Als nächster Schritt wurde deshalb eine automatisierte Auswertung und Alarmierung aufgesetzt.

Da die Daten in einer Datenbank gespeichert und für den Oracle Enterprise Manager Datenbanken ein Target sind, auf dem man Reports definieren und verschicken kann, hat man sich für diese Lösung entschieden. Es wurden Reports aufgebaut, und

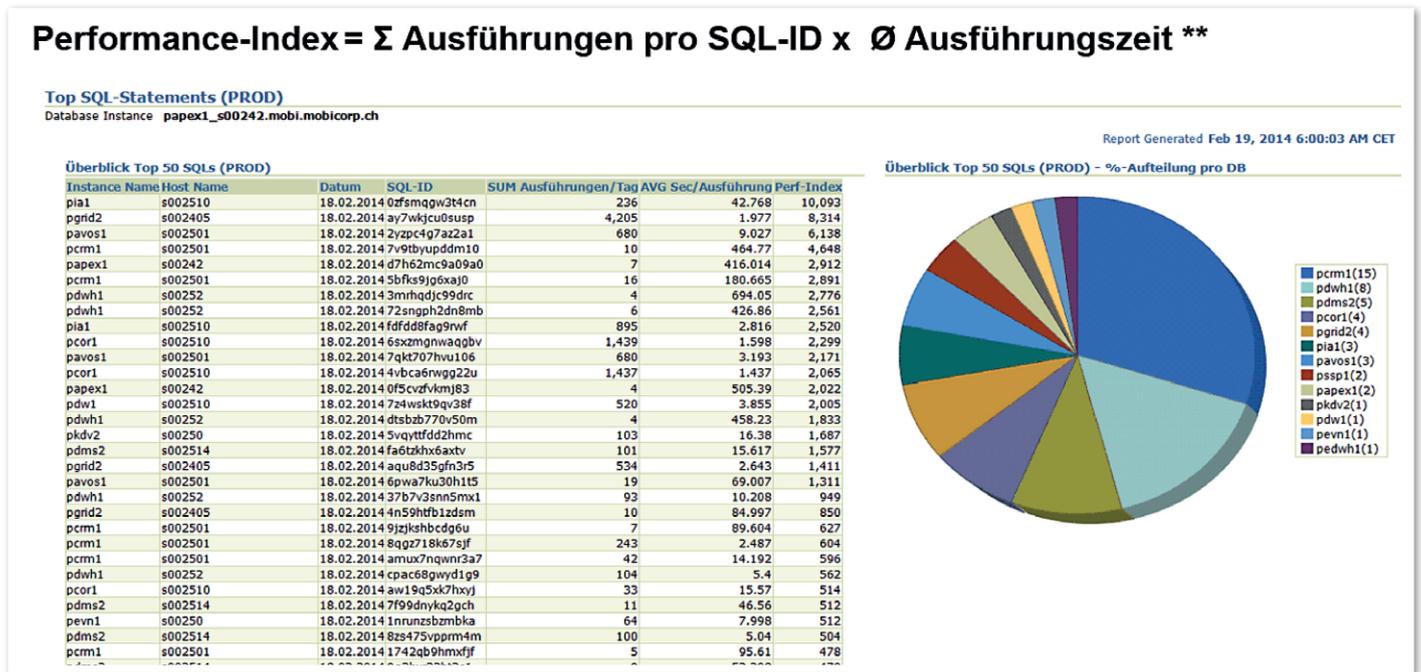


Abbildung 6: Top-SQL aller Datenbanken anhand eines definierten Performance-Index

DB-Benutzer	Database	SNAP_TIME	SQL_ID	NBOIExec	Avg Time Per Exec	Sum Elap TimeTot_Sec	Avg Cpu Time Per Exec	Sum Cpu Time Tot_Sec	Avg Iowait Time Per Exec	Sum Iowait Tot_Sec
AO_DMS1	pdms1	09.FEB.2014 09:00:00	0ua9d8vkhqy1	10561	2.37	25029.89	1.54	16256.08	.01	117.568
AO_DMS1	pdms1	09.FEB.2014 10:00:00	0ua9d8vkhqy1	10513	2.13	22395.721	1.49	15709.06	.01	83.687
AO_DMS1	pdms1	09.FEB.2014 11:00:00	0ua9d8vkhqy1	10505	2.01	21102.802	1.44	15109.36	.01	80.964
AO_DMS1	pdms1	09.FEB.2014 13:00:00	0ua9d8vkhqy1	10335	1.71	17703.665	1.24	12801.21	.01	97.951
AO_DMS1	pdms1	09.FEB.2014 12:00:00	0ua9d8vkhqy1	10122	1.99	20121.67	1.37	13860.49	.01	93.9
AO_DMS1	pdms1	09.FEB.2014 08:00:00	0ua9d8vkhqy1	7959	2.33	18539.27	1.52	12072.43	.03	202.338
AO_DMS1	pdms1	09.FEB.2014 16:00:00	0ua9d8vkhqy1	2068	1.11	2291.401	.77	1585.59	.01	23.681
AO_DMS1	pdms1	09.FEB.2014 15:00:00	0ua9d8vkhqy1	1882	1.16	2174.454	.83	1571.18	.01	22.912
AO_DMS1	pdms1	09.FEB.2014 14:00:00	0ua9d8vkhqy1	1339	1.41	1888.033	.94	1256.68	.01	17.87
AO_DMS1	pdms1	15.FEB.2014 18:00:00	0ua9d8vkhqy1	1294	1.18	1528.7	.68	884.53	.04	52.068
AO_DMS1	pdms1	09.FEB.2014 07:00:00	0ua9d8vkhqy1	1151	1.22	1408.167	.71	819.45	.07	76.427
APP_TABU	plabu1	10.FEB.2014 12:00:00	cca589hkzbdsc	1118	.95	1062.776	.78	877.413	0	0
GISEXPERT	pkgis3	14.FEB.2014 08:00:00	4zj7d195wvzb5	787	2.23	1755.58	2.22	1743.519	0	.824

Abbildung 7: Top-SQLs pro Datenbank und Zeiträumen, sortierbar nach CPU- und I/O-Verbrauch

INSTANCE_NAME	HOST_NAME	DATUM	SQL_ID	SUM_EXEC_PER_DAY	AVG_SEC_PER_EXEC	PERF_INDEX	CNT_TOP10_CUR_MONTH	CNT_TOP10_LAST_12_MONTHS
pia1	s002510	18.02.2014	0zfsmqgw3t4cn	236	42,7681818181818	10093	13	180
pgrid2	s002405	18.02.2014	ay7wkjcu0sus	4205	1,97708333333333	8314	19	249
pavos1	s002501	18.02.2014	2yzpc4g7az2a1	680	9,02666666666667	6138	19	108
pcrm1	s002501	18.02.2014	7v9tbyupddm10	10	464,77	4648	15	92
papex1	s00242	18.02.2014	d7h62mc9a09a0	7	416,014285714286	2912	13	13
pcrm1	s002501	18.02.2014	5bfks9jg6xaj0	16	180,665	2891	12	55
pdwh1	s00252	18.02.2014	3mrhqjdc99drc	4	694,05	2776	11	93
pdwh1	s00252	18.02.2014	72sngph2dn8mb	6	426,86	2561	15	182
pia1	s002510	18.02.2014	fdfd8fag9rnf	895	2,81583333333333	2520	13	180
pcor1	s002510	18.02.2014	6sxzmggnwaqgbv	1439	1,5975	2299	14	24
pavos1	s002501	18.02.2014	7qkt707hvu106	680	3,19333333333333	2171	19	108
pcor1	s002510	18.02.2014	4vbca6rvvgg22u	1437	1,43708333333333	2065	14	24
papex1	s00242	18.02.2014	0f5cvzfvkmj83	4	505,39	2022	13	13
pdw1	s002510	18.02.2014	7z4wskt9qv38f	520	3,855	2005	13	178
pdwh1	s00252	18.02.2014	dtsbzb770v50m	4	458,23	1833	14	23
pkdv2	s00250	18.02.2014	5vqytfdd2hmc	103	16,38	1687	16	218
pdms2	s002514	18.02.2014	fa6tzkx6axtv	101	15,6166666666667	1577	14	171
pgrid2	s002405	18.02.2014	aqu8d35gfn3r5	534	2,643	1411	17	245

Abbildung 8: Top-SQLs pro Datenbank mit Jahres- und Monats-Frequenz

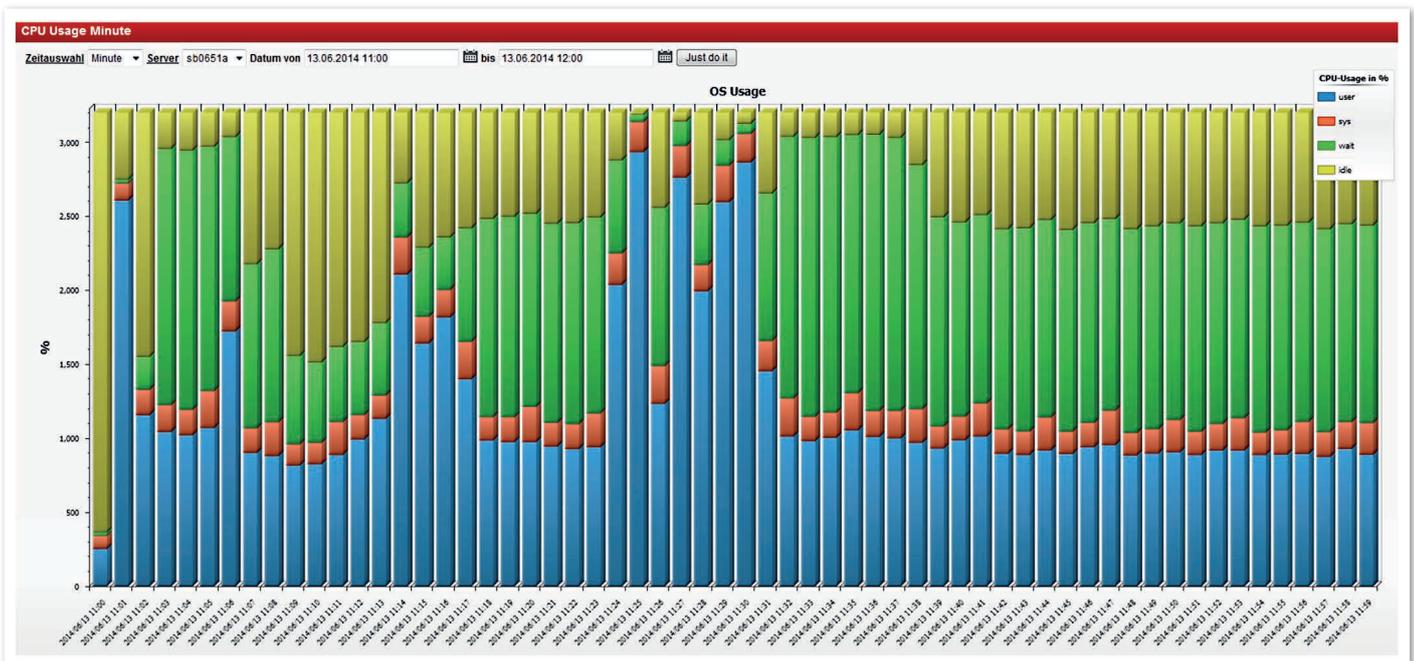


Abbildung 9: CPU-Verbrauch auf einem Server

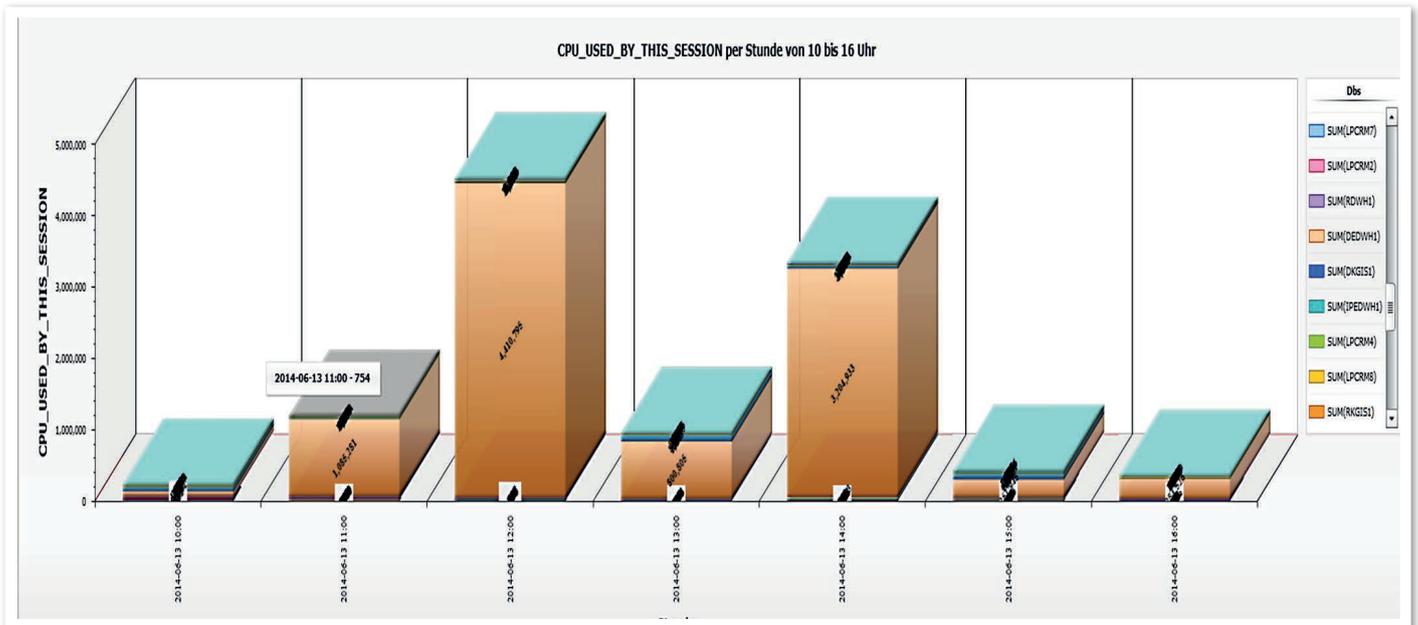


Abbildung 10: CPU_USED_BY_THIS_SESSION: Verursacher ist klar: Datenbank „dedwh1“

diese werden heute täglich verschickt (siehe Abbildung 4, 5 und 6).

Für „Ad-hoc-Analysen“ können direkt in Apex weitere Masken aufgerufen werden, etwa „Auswertungen über Top-SQL-Statements sortierbar nach CPU- und I/O-Verbrauch“ über die gesamte Landschaft, die aus Active-Session-History-Daten stammen, „Auswertungen über Top-SQLs pro Datenbank“ oder auch „Frequenz des Auftretens eines SQL-Statements in den Top 10 pro Tag“ (siehe Abbildung 7 und 8).

Erweiterung auf OS-Performance-Metriken

Später wurden zusätzlich in der gleichen Datenbank Performance-Daten auf CPU-, Memory- und I/O-Ebene geladen, um Auswertungen und Korrelationen zwischen OS-Engpässen und Datenbanken-Ressourcen-Verbrauch auswerten zu können. Antworten auf Fragen wie „Welche Datenbank ist der Verursacher der CPU-Last auf einem Server?“ sind durch einen Ab sprung von den CPU- auf die Datenbank-Metriken mit einem Klick möglich.

Die Daten vom Betriebssystem stammen aus NMON-Daten, die täglich erhoben und geladen werden. Der Vergleich mit den Datenbanken ist durch Performance-Statistiken und Active Session History möglich. In den Abbildungen 9, 10 und 11 sind eine CPU-Auslastung auf einem Server und der Vergleich des CPU-Verbrauchs durch Performance-Statistiken („CPU_USED_BY_THIS_SESSION“) und Active Session History ersichtlich.



Abbildung 11: ASH Wait Events und Samples im gewählten Zeitraum bestätigen das Resultat

Neue Themen

Zu einem späteren Zeitpunkt wurde klar, dass auch andere Daten, die in den Instanzen gespeichert sind, nützlich für Auswertungen sein können. Themen wie „Lizenzverwaltung“, „Gewalten-Trennung zwischen Entwickler und Betrieb“ und „Wachstums-Statistiken“ (um Kosten und Investitionen zu begründen) ließen sich durch Sammeln von Data-Dictionary- und Session-Informationen beantworten.

Leider kann man in einer Oracle-Datenbank einige Features, die kostenpflichtig sind, nicht ausschalten. Es ist von Oracle auch nicht geplant, es irgendwann ausschalten zu dürfen (siehe Tech-Note 1459216.1 und dazugehörigen Bug). Fehler können

schnell passieren: Es gibt Datenbank-Verwaltungstools, die Tabellen per Default als Compressed Advanced erstellen. Auch über Data Pump kann es passieren, dass man auf einmal Features benutzt, die man gar nicht lizenziert hat (Option „Compression = ALL“). Die Datenbank merkt sich den Zugriff auf jede Option und diese Informationen sind dann bei einem Audit auswertbar. Als Ziel setzte man sich, mindestens informiert zu sein, sobald ein Fehler aufgetreten war. Durch regelmäßige Abfragen auf der View „DBA_FEATURE_USAGE_STATISTICS“ ist man in der Lage, Lizenzverletzungen und deren Anzahl auszuwerten. In Abbildung 12 ist der Inhalt der View bei einem Test ersichtlich. Der Export wurde einmal am 29. Februar

A	B	C	D	E	F
db_name	Collect_ts	Product	Feature_being_used	Usage	Last_Sample_Date
test1	23.10.2016 23:06	Advanced Compression	Oracle Utility Datapump (Export)	4.PAST_USAGE	29.02.2016 14:49

G	H	I	J	K
Detected_usage	Total_samples	First_usage	LastUsage	Extra_Feature_Info
1	1	29.02.2016 14:49	29.02.2016 14:49	compression used: 1 times

Abbildung 12: „DBA_FEATURE_USAGE_STATISTICS“ zeigt an, wann und wie oft Data Pump mit „Compression = ALL“ benutzt wurde.

COLLECT_TS	BE0B_ZTR_VON	BE0B_ZTR_BIS	OSUSER	NAME	NACHNAME	ORGIN	ORGANISATION	LOGIN_USER	DB_NAME	ANZ_LOGINS	LETZTES_LOGIN	PROGRAM	MACHINE
01.10.2016	01.09.2016	30.09.2016	OSUSER1	Hans1	Muster1	AFAFAB	unCayrtsoeimtcAsl	PASA_PS	dh1pw	4	05.09.2016 14:49:34	Toad.exe	3M7IS\2FOCB
01.10.2016	01.09.2016	30.09.2016	OSUSER2	Hans2	Muster2	EAABAF	culCiyme ttaonsArs	_PSASPA	hp1dw	10	29.09.2016 10:54:20	Toad.exe	CBM900B1C39\
01.10.2016	01.09.2016	30.09.2016	OSUSER3	Hans3	Muster3	BAAEFA	omtr syutiAcaleCsn	UABSPPA_S_	hwpd1	6	16.09.2016 10:00:46	Toad.exe	3\B90COB8CM19
01.10.2016	01.09.2016	30.09.2016	OSUSER4	Hans4	Muster4	ABEAFA	tiuACanolmtyscers	HWUEUDRS	wpdh1	2	16.09.2016 07:19:24	Toad.exe	IOC91B9MC30\B
01.10.2016	01.09.2016	30.09.2016	OSUSER5	Hans5	Muster5	FAADAA	PSN	ISLEEB	cmrp1	44	22.09.2016 07:53:14	Toad.exe	SB8017216\M
01.10.2016	01.09.2016	30.09.2016	OSUSER6	Hans6	Muster6	ABAFBA	a(yicsrkeiunohSttnA	PAKET_NTAPR	ao1pe	1	05.09.2016 15:51:08	aqtv10.exe	T\000MC709CB2
01.10.2016	01.09.2016	30.09.2016	OSUSER7	Hans7	Muster7	FABABA	aAttrcr)m(fyaiSsomk	PRKATPETNA_	poa1e	1	02.09.2016 09:41:26	aqtv10.exe	96MCOI05801C\
01.10.2016	01.09.2016	30.09.2016	OSUSER8	Hans8	Muster8	AFCABA	ehAr)lnTocgkeuchT a	A_ATKETPNPR	ape1o	4	19.09.2016 09:51:46	SQL Developer	9c0d4c0c
01.10.2016	01.09.2016	30.09.2016	OSUSER9	Hans9	Muster9	AAFCFB	eM ebSliSM	IELSEB	prmc1	15	15.09.2016 09:55:36	SQL Developer	0c46bc90
01.10.2016	01.09.2016	30.09.2016	OSUSER10	Hans10	Muster10	BAFCCA	l MSbMSeei	IEEBLS	pcm1r	12	15.09.2016 09:05:50	Toad.exe	\9167809COCMO
01.10.2016	01.09.2016	30.09.2016	OSUSER11	Hans11	Muster11	AAFCFB	eMeS libMS	ESLEIB	pm1rc	170	26.09.2016 08:23:07	Toad.exe	SM9\917O28B
01.10.2016	01.09.2016	30.09.2016	OSUSER12	Hans12	Muster12	BFCACA	MMSlibeiS	SIEELB	pmc1r	6	06.09.2016 15:57:25	SQL Developer	97B92S
01.10.2016	01.09.2016	30.09.2016	OSUSER13	Hans13	Muster13	AFACCB	M ebSlelMS	ELSBEI	cp1rm	6	30.09.2016 19:32:51	SQL Developer	09cac700
01.10.2016	01.09.2016	30.09.2016	OSUSER14	Hans14	Muster14	ABACFB	SeMli bSeM	AMINSID	cr1mp	4	15.09.2016 09:39:22	Toad.exe	B6\20SM78JF
01.10.2016	01.09.2016	30.09.2016	OSUSER15	Hans15	Muster15	AAFCFB	SeebSliM M	ILBESE	1rmrc	6	15.09.2016 09:56:56	Toad.exe	BMO\268JF7S
01.10.2016	01.09.2016	30.09.2016	OSUSER16	Hans16	Muster16	ABFCCA	libSMM ee	EEBISL	prc1m	4	20.09.2016 09:33:32	SQL Developer	0b9001cc
01.10.2016	01.09.2016	30.09.2016	OSUSER17	Hans17	Muster17	ABCFAC	libSMe MSe	BILESE	1mrpc	6	09.09.2016 17:04:20	SQL Developer	c2c90909
01.10.2016	01.09.2016	30.09.2016	OSUSER18	Hans18	Muster18	FCBAAC	ISem ebSliM	LESIEB	cr1pm	3	06.09.2016 08:25:44	SQL Developer	c08c5019
01.10.2016	01.09.2016	30.09.2016	OSUSER19	Hans19	Muster19	CAACFB	eSli SMMeb	ISEBEL	pcr1m	4	15.09.2016 13:25:27	sqlplus.exe	98C3B\M1000C
01.10.2016	01.09.2016	30.09.2016	OSUSER20	Hans20	Muster20	CAACFB	MIMSS ebei	EEILSB	1mrpc	3	08.09.2016 17:46:03	sqlplus.exe	9C290019C\BMO

Abbildung 13: Session-Informationen zur Gewaltentrennung

2016 (Felder „First_Usage“ und „Last_Usage“) getätigt und registriert. Im letzten Feld („Extra_Feature_Info“) ist ersichtlich, dass das Feature wirklich nur einmal benutzt wurde. Die Information ist noch am 26.10.2016 in der Datenbank ersichtlich (Feld „Collect_ts“, entspricht letztes Load der View im Performance-Warehouse).

Gewalten-Trennung

In der Mobiliar wurde entschieden, die Zugriffsrechte auf Datenbanken außerhalb des Informatik-Betriebs einzuschränken. In diesem Zuge tauchte die Frage auf, ob beispielsweise Entwickler durch Applikations-User direkt Zugriff auf die Produktion hätten. Um hierzu eine Antwort zu liefern, benutzte man Data Dictionary Views, die zentralisiert im Performance Warehouse geladen werden. Die Berechtigungen eines persönlichen Users wurden zentral ausgewertet und Reports erstellt, die einer Bereinigung dienen. Die Berechtigungen eines Users sind schlussendlich in verschiedenen Views enthalten, wie „DBA_ROLE_PRIVS“, „DBA_SYS_PRIVS“ etc.

Aber was ist mit dem Applikations-User? Hätte sich ein Entwickler über einen Datenbank-Client auch direkt anmelden können, falls ihm das Passwort bekannt ist? Durch ein

Logon-Trigger werden verschiedene Informationen bei der Anmeldung einer Session auf einer Datenbank gesammelt, unter anderem das benutzte Programm, die User-ID, der Client – von dem aus die Session gestartet wurde – und natürlich der Datenbank-User. Diese Daten werden täglich im Performance Warehouse geladen und historisiert. Somit ist eine Auswertung über beliebige Zeitabschnitte aller Verbindungen zu einer Datenbank möglich. In *Abbildung 13* sind Zugriffe über User, mit Schreibrechten, auf produktiven Datenbanken, über Datenbank-Clients wie Toad, SQL Developer und andere ersichtlich (sensible Daten wurden anonymisiert). Basierend auf diese Daten wurde ein Report für den Security Officer aufgesetzt.

Fazit

Was mit ein paar Views anfing, ist mittlerweile zu einem großen Data Warehouse gewachsen. Heute bewirtschaftet man mehr als 3 TB Performance- und Data-Dictionary-Daten. Die größte Tabelle hat mehr als 1,5 Milliarden Einträge und ist in 60 Partitionen aufgeteilt. Nicht nur Performance-Ausreißer werden zeitnah und automatisch entdeckt, sondern es können auch Wachstums-Statistiken erhoben werden und die Lizenz-Benutzung wird überwacht. Da das Performance

Warehouse vom DBA-Team selbst entwickelt wurde, ist die Akzeptanz des Tools sehr hoch. Jedes Team-Mitglied hat Kenntnis der DBA-Views, der verschiedenen Partitionierungsmethoden und auch der Lizenz-Regeln. Da wir demnächst unsere Datenbanken mit der Multitenant-Option konsolidieren werden, ist man bereit, ab der Version 12.2, in der AWR-Daten auf PDB-Ebene ersichtlich sind, die Last einzelner PDB auswerten zu können. Täglich kommen neue Ideen für Auswertungen aus dem Team hinzu und neue Erkenntnisse werden gesammelt.

Paolo Kreth
paolo.kreth@mobi.ch



Digitale Transformation in Unternehmen

Dr. Thomas Kofler, Zentrum Digitalisierung.Bayern

Die digitale Transformation stellt Unternehmen vor große Herausforderungen. Für Unternehmen gibt es eine Vielzahl von Informationen zu diesem Thema. Ein Großteil der verfügbaren Informationen behandelt punktuelle Handlungsfelder. Dieser Artikel gibt einen Überblick über das Thema „Digitale Transformation“; diskutiert Themenfelder und stellt abschließend mögliche Handlungsfelder dar.

Die digitale Transformation (DT) bezeichnet einen fortlaufenden, in digitalen Technologien begründeten Veränderungsprozess, der alle Bereiche der Gesellschaft betrifft und besonders auf Unternehmen enorme Auswirkungen hat. Getrieben wird sie neben den digitalen Technologien durch die Erwartungen der Kunden an digitale Technologien [1] und deren Einsatz, etwa in Unternehmen. Die sich fortlaufend ändernden Anforderungen an Unternehmen durch die Erwartungen der Kunden, neue Wettbewerber und digitale Technologien führt zu einer raschen Veränderung der Unternehmenslandschaft mit weitreichenden Folgen. Für viele Unternehmen bedeutet die DT ein

Kampf ums Überleben [1]. Umso wichtiger ist es, die treibenden Kräfte zu verstehen und darzustellen, welche Veränderungen auf Unternehmen zukommen und welche Handlungsfelder existieren, um die DT aktiv innerhalb des Unternehmens zu begehen.

Digitale Transformation innerhalb der Unternehmen

Die DT im Unternehmen endet nicht. Märkte im digitalen Zeitalter ändern sich schnell und fortwährend. Die Kunden sind informierter denn je, dies ist auch für die Unternehmen direkt wahrnehmbar. Die Unternehmen müssen sich nicht nur an die veränderten Kundenerwartungen anpassen, sondern

den Kunden auch einen Wert anbieten, der die Erwartungen im besten Fall übertrifft beziehungsweise Bedürfnisse befriedigt, von denen der Kunde gar nicht wusste, dass er sie hat. Ein primäres Ziel der Unternehmen in der DT ist daher, den Kunden zu verstehen; das Schlüsselwort dazu ist „Empathie“ (siehe Abbildung 1).

Der Kunde ist technologisch mündig und verwendet digitale Technologien mit einer Selbstverständlichkeit. Neue digitale Technologien werden, sofern sie Nutzen stiften, rasch adaptiert und ändern damit auch die Erwartungen an die Verwendung neuer Technologien innerhalb der Unternehmen an der Kunden-Schnittstelle.

Digitale Transformation in Unternehmen: Zusammenhänge

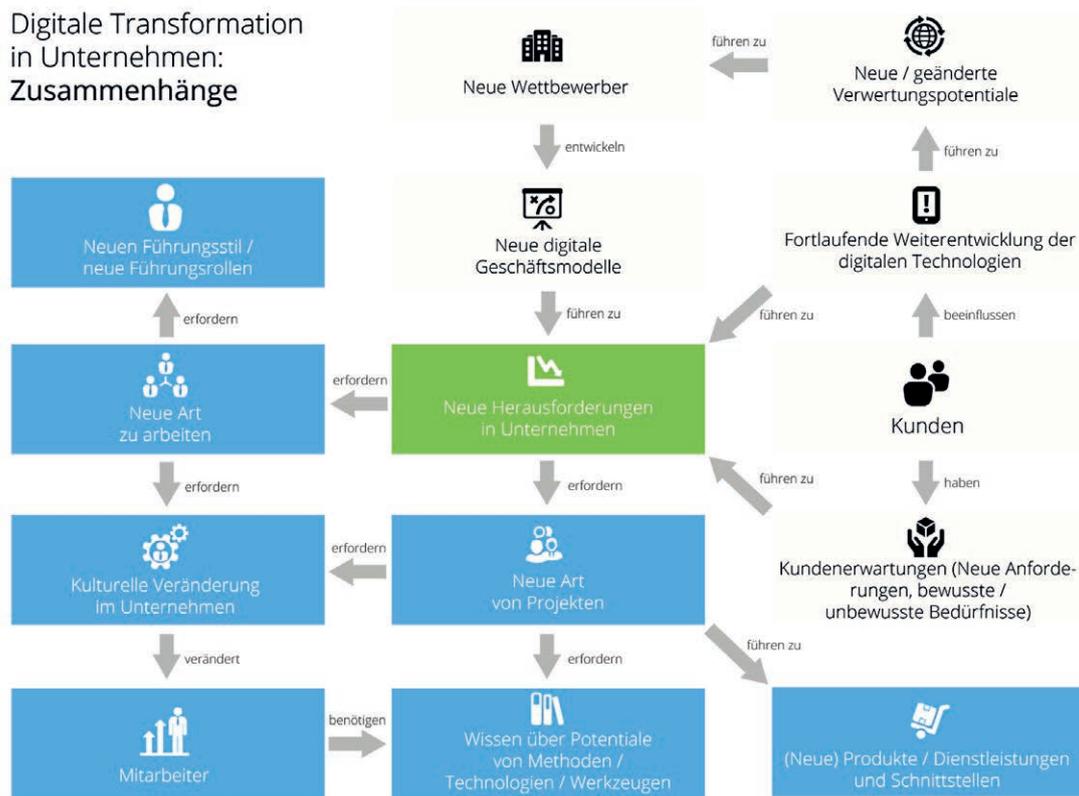


Abbildung 1: Übersicht über wichtige Faktoren der digitalen Transformation in Unternehmen. Grau eingezeichnet sind (primär) externe Einflussfaktoren und Entitäten, blau die internen.

Digitale Technologien führen aber auch zu neuen Verwertungspotenzialen, die beispielsweise wieder in neue digitale Technologien münden oder in Geschäftsmodelle, die von etablierten wie auch neuen Unternehmen operationalisiert werden. Sofern diese neuen Geschäftsmodelle gefährdend für die Geschäftstätigkeit eines Unternehmens sind, üben sie einen enormen Druck auf etablierte Unternehmen und deren Geschäftsmodell aus. Geschäftsmodelle sind ebenso einer Veränderung ausgesetzt; vielfach sind in den vergangenen Jahren etablierte Geschäftsmodelle verschwunden. Die digitalen Technologien führen nicht nur zu neuen Geschäftsmodellen, sondern sie machen auch vorhandene teilweise obsolet.

Es sind drei wesentliche Faktoren, die dazu führen, dass Unternehmen vor neuen Herausforderungen stehen: die geänderten Kundenerwartungen (neue Anforderungen wie auch bewusste und unbewusste Bedürfnisse), die fortlaufende Entwicklung der digitalen Technologien und der Druck, diese zu adaptieren, sowie neue Wettbewerber, die etablierte Geschäftsmodelle verdrängen oder obsolet machen.

Nach einer Umfrage von Roland Berger [2] sehen noch immer 43 Prozent der Top-Manager der deutschen Wirtschaft vor allem die Kostenreduktion als Zielsetzung der DT. 32 Prozent sehen die Umsatzsteigerung mit neuen Produkten als Zielsetzung. Diese Zielsetzungen sind ein Resultat des Einsatzes von digitalen Technologien in Unternehmen beziehungsweise der Entwicklung von neuen Produkten. Die digitale Technologie betrifft ein Unternehmen aber im Kern. Sie verlangt vor allem eine Antwort auf die Frage, ob geänderte Anforderungen (an Technologie, an Kundenerwartungen) überhaupt in einem annehmbaren Zeitrahmen umgesetzt werden können. Kostenreduktion ist ein Seiteneffekt dieses Transformations-Prozesses, aber nicht der Kern.

Eine neue Art von Projekten

Projekte zum Entwickeln beziehungsweise Anpassen von Produkten/Dienstleistungen oder auch internen Informationssystemen werden in jedem Unternehmen durchgeführt. Typischerweise finden sie in etablierten Unternehmen unter Einbezug von wohlbekanntem Anforderungen der internen/

externen Kunden und wohlbekanntem, und daher beherrschten, Technologien statt. Die sich fortlaufend ändernden Kundenerwartungen führen zu volatileren Anforderungen innerhalb von Projekten und die sich ständig weiterentwickelnden Technologien verursachen Unsicherheiten in der Technologie-Auswahl und deren Einsatz. Diese Rahmenbedingungen erlauben es nicht mehr, ein Projekt vollständig und zeitgenau durchzuplanen. Daher eignen sich die etablierten, wasserfallartigen Vorgehensweisen nicht für solche Projekte. Ein genauer Zeit- und Kostenplan kann nur im bekannten Umfeld erstellt werden. Sobald in einer Dimension unbekannte Faktoren einfließen, wird eine Zeit- und Kostenplanung zu einer wagen Schätzung.

Für solche Projekte eignen sich eher agile Vorgehensweisen (siehe Abbildung 2). Im Bereich Software Engineering wurden in den vergangenen Jahren (2011-2015) 39 Prozent der agilen und nur 11 Prozent der wasserfallartigen Software-Projekte (unter Einhaltung des Zeit- und Kosten-Budgets) erfolgreich abgeschlossen [3].

Hinzu kommt, dass bei der Adaption von Technologien und beim Reagieren auf die

neuen Kundenanforderungen rasches Anpassen auf diese Gegebenheiten gefordert ist. Die Vergangenheit lehrt uns, dass häufig schon ein Software-Entwickler reicht, um einen Markt zu verändern und um Nischen zu füllen, die für große Unternehmen als unrentabel gelten.

Die Geschwindigkeit der Projekt-Initiierung und -Durchführung ist entscheidend. In Projekten der Zukunft benötigen Mitarbeiter daher zunehmend die Kompetenzen, Probleme, die während der Realisierung eines Projekts auftreten, selbstverantwortlich und autonom zu lösen, ohne dafür langwierige Projekt-Änderungsprozesse anzustoßen. Dabei müssen die Mitarbeiter abteilungsübergreifend an den Projekten direkt mitarbeiten und ihre Kompetenz einbringen. Das Steuern eines Projekts von oben herab wird folgerichtig dadurch auch schwieriger.

Die neue Art zu arbeiten

Mitarbeiter sind der wesentliche Erfolgsfaktor in der DT [4]. Es wird einerseits Kreativität von den Mitarbeitern gefordert, andererseits werden aber nicht die entsprechenden Handlungsräume dafür geschaffen. So werden etwa zu oft talentierte Mitarbeiter durch künstliche Barrieren aufgehalten, die Ideen nicht nach oben durchreichen können, weil das mittlere Management um seine Position fürchtet oder kritische Entscheidungen ohne Einsichten der Mitarbeiter gefällt werden, weil diese nicht gesammelt werden [5].

Weil Freiraum eine Voraussetzung für Kreativität ist, müssen Unternehmen in der DT lernen, dass sie den Mitarbeitern Freiraum gewähren müssen, damit diese produktiv und kreativ arbeiten können. Mitarbeiter, die eine kognitiv anspruchsvolle Tätigkeit haben, erreichen die höchste Produktivität dann, wenn sie mehr Freiheit haben zu entscheiden, zu welchen Zeiten und an welchen Orten sie arbeiten [6]. Für Unternehmen bedeutet dies, dass sich das Vertrauensverhältnis zu den Mitarbeitern ändern muss. Sie müssen lernen, den Mitarbeitern zu vertrauen.

Menschen haben eine natürlich intrinsische Motivation, sinnvolle Aufgaben eigenverantwortlich zu erledigen. Sind die Grundbedürfnisse gedeckt, engagieren sich Menschen auf Dauer und intensiver für sinnvolle Vorhaben [7]. Dagegen hat sich gezeigt, dass Bonuszahlungen, Leistungsanreize und andere Anreizsysteme dem gemeinsamen Streben der Mitarbeiter, der Zusammenarbeit sowie der Kreativität massiv entgegenwirken [8].

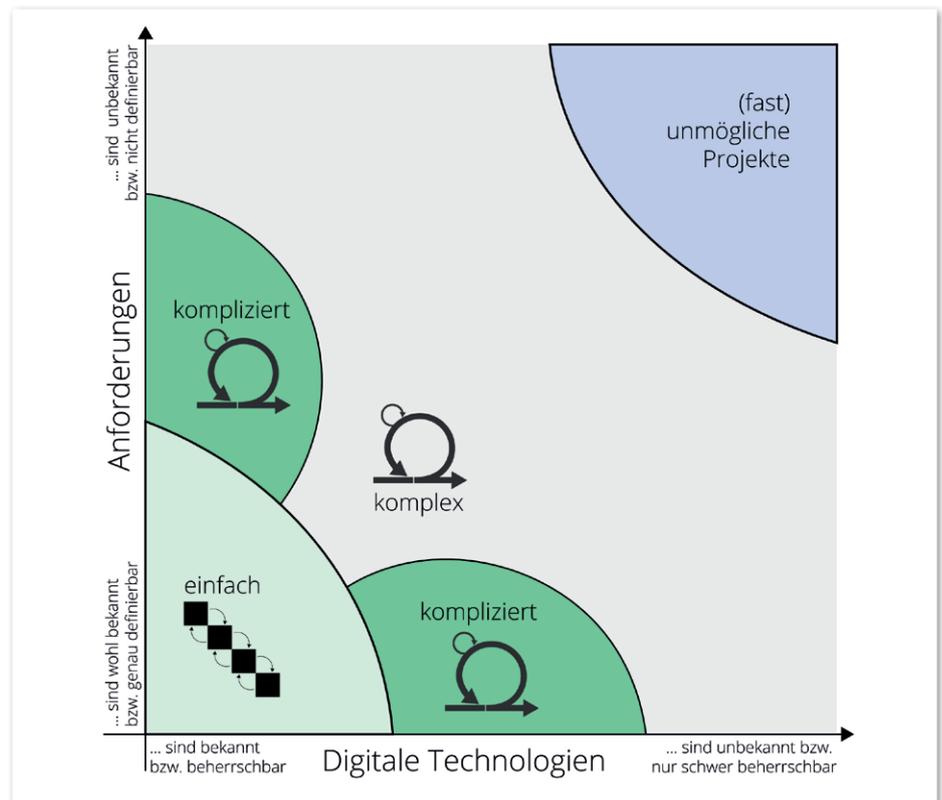


Abbildung 2: Darstellung von Projektarten unter Einbezug von Anforderungen und Technologien in einer Stacey-Matrix. Zu sehen ist auch das Vorgehensmodell, das sich für die Projektarten eignet. In komplizierten wie komplexen Ausgangssituationen eignen sich eher agile Vorgehensweisen.

Die Zusammenarbeit unter Mitarbeitern ist für die Änderungsprojekte der DT von großer Bedeutung, selbstorganisierende Teams werden zu ihrem Handeln befähigt und ermächtigt, die entsprechenden Freiräume führen auch zu Freiräumen in den Lösungsansätzen [9], genau diese Kreativität benötigen Unternehmen.

Innerhalb von Unternehmen ist die DT vor allem ein sozialer Akt. Soziale Kompetenz wird wichtiger denn je. Der Erfolgsfaktor im 21. Jahrhundert ist es, Schlüsselpositionen mit Mitarbeitern zu besetzen, die menschliche Reife aufweisen, „Survival of the Fittest“ war gestern [7]. Dies erfordert aber auch ein Umdenken darüber, wie Mitarbeiter für ein Unternehmen gewonnen werden. Ein Recruiting nach Einträgen in Beruf und Ausbildung im Lebenslauf ermöglicht es nicht, die Personen zu identifizieren, die in der Lage sind, über den Tellerrand zu blicken, Technologien sowie deren Potenziale einzuschätzen und zu kombinieren und dabei die eigenen Mitarbeiter auch inhaltlich mitzunehmen.

Wissen über die Potenziale

Unternehmen ohne Wissen und Kompetenz in der Programmierung werden zum Spiel-

ball externer Kräfte [10]. Nun muss nicht jedes Unternehmen Software entwickeln, jedoch ist die Anpassung von Software eine Voraussetzung, um sich von anderen Unternehmen abgrenzen beziehungsweise Teil eines Wertschöpfungs-Netzwerks werden zu können. Das agile Anpassen der eingesetzten Software an geänderte Marktbedingungen ermöglicht einen Wettbewerbsvorteil (etwa dann, wenn ein Unternehmen kurzfristig in der Lage ist, neue Technologien zu adaptieren und so den Kundennutzen zu mehren). Dafür hat sich der Begriff „DevOps-Teams“ etabliert. Das sind Entwicklungsteams, die die Programmierung und den Betrieb gleichzeitig verantworten. Eine solche Konstellation hat auch den Vorteil, dass, wenn sie In-House betrieben wird, auch kurzfristig auf Kompetenzen der Abteilungen des Unternehmens zurückgegriffen werden kann. Diese Art von agiler Organisation von Anpassung und Software-Entwicklung hebt die Trennung von Planung und Ausführung auf [11].

Das Wissen über Methoden, Technologien und Werkzeuge wird zunehmend auch für die Unternehmensführung ein Erfolgsfaktor. Die DT muss von oben ermöglicht werden, Potenziale erkannt und der Fortschritt im Auge be-

halten werden. Dies gilt insbesondere für die Personen, die Unternehmen lenken.

Die in *Abbildung 3* dargestellten Begriffe sind ein Ausschnitt aus Methoden, Technologien und Werkzeugen, die zum neuen Grundwortschatz der Führungskräfte gehören müssen. Gerade in der Unternehmensführung herrscht noch Selbstüberschätzung der eigenen digitalen Kompetenz. 44,1 Prozent der Unternehmensführung schätzt die eigene digitale Kompetenz als „hoch“ oder „sehr hoch“ ein, wohingegen die eigenen Mitarbeiter die digitale Kompetenz der Unternehmensführung nur zu 13,9 Prozent als „hoch“ oder „sehr hoch“ einschätzen [12].

Ein geübter Anwender von digitalen Technologien zu sein, reicht nicht aus, um tiefergehende Zusammenhänge erkennen und Potenziale einschätzen zu können. Der richtige Technologieeinsatz führt einerseits zu den bereits bekannten Einsparungen, viel wichtiger ist es jedoch, herausragende Werte für die Kunden zu schaffen und die eigenen Produkte und Dienstleistungen zu verbessern beziehungsweise neu zu denken, eben im Rahmen der technologischen und kulturellen Möglichkeiten eines Unternehmens.

Der Kunde

Wie bereits erwähnt, ist das Verstehen des Standpunkts eines (potenziellen) Kunden

zentraler Gegenstand der DT. Das Schlüsselwort ist „Empathie“. Diese ist insbesondere deswegen notwendig, weil der Kunde nicht unbedingt das wünscht, was er braucht. Vor allem geht es um das Erkennen von Bedürfnissen, die der Kunde bislang selbst noch nicht in der Lage war zu formulieren. Diese Produkte und Dienstleistungen, die genau dies schaffen, werden häufig auch als disruptive Produkte und Dienstleistungen bezeichnet, weil sie das Potenzial haben, ein evolutionär entwickeltes Produkt und/oder Dienstleistung zu ersetzen. Wobei diese disruptiven Produkte und Dienstleistungen typischerweise am unteren Rand der Leistungsanforderungen der Kunden starten, aber auf einer anderen (technologischen) Basis und mit der Zeit mehr Potenzial bieten, dem Kunden sowie seinen dann neuen und sich entwickelnden Bedürfnissen gerecht zu werden.

Der Kunde hat sich allerdings auch durch die Informationsvielfalt verändert. Er ist per se besser informiert und erwartet eine große Auswahl mit hoher Qualität zu niedrigen Preisen und dabei gleichzeitig guten Services. Darüber hinaus will er als Kunde Wertschätzung sowie maßgeschneiderte Angebote erhalten – und das unabhängig von Raum und Zeit und mit rascher Leistungserbringung [13].

Abbildung 4 zeigt den Weg eines Kunden („Customer Journey“) von der Bewusstseins-

bildung über den Kauf bis hin zur Für- oder Gegenseite (von Produkten oder Dienstleistungen) mit möglichen Interaktionspunkten. Diese Interaktionspunkte sind für Unternehmen essenziell, weil eine Interaktion mit dem Kunden bereits lange vor dem eigentlichen Abschluss eines Geschäftes stattfindet. So kann ein Unternehmen etwa durch aktives Community-Management bereits lange vor dem Kauf auf die eigenen Produkte und Dienstleistungen aufmerksam machen, die Wünsche der Kunden ins Unternehmen zurückführen und so die eigenen Produkte und Dienstleistungen verbessern.

Hinzu kommt, dass Kunden inzwischen selbst zu Für- oder Gegenseitern von Produkten werden. So teilen aktive Kunden Produkttests auf Video-Plattformen oder schreiben Blog-Artikel dazu. Sie sind daher schon der Beginn des Wegs eines nächsten potenziellen Kunden. Der Kunde wird daher mehr denn je zu einem aktiven, nicht einfach kontrollierbaren Teil des Unternehmenserfolges.

Darüber hinaus gibt es natürlich eine Vielzahl von Möglichkeiten, die Kunden aktiv in die Produkt- und Dienstleistungsentwicklung einzubeziehen oder aus den Daten der vergangenen Interaktionen mit den Kunden zu lernen. Wichtig ist vor allem zu verstehen, dass sich die Rolle des Kunden verändert.

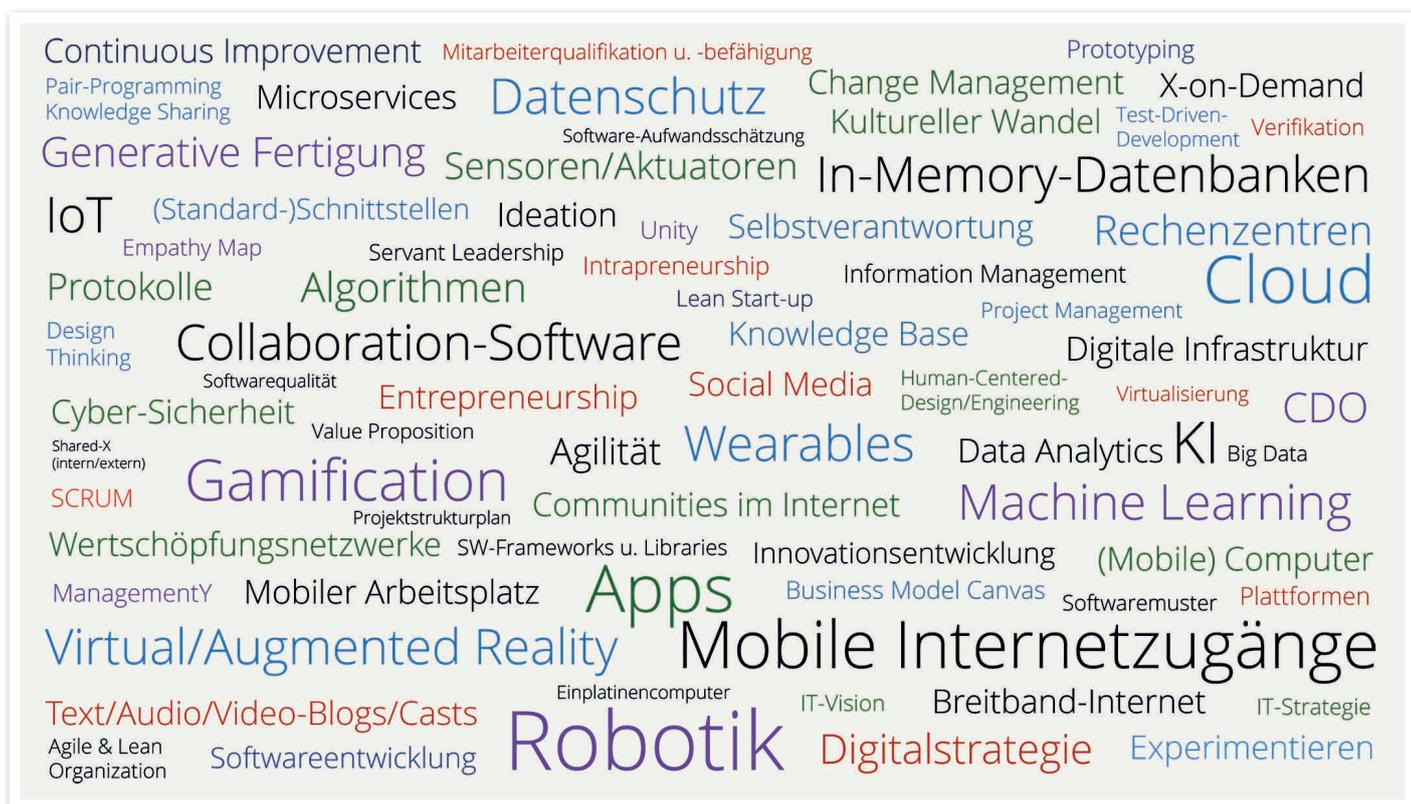


Abbildung 3: Wichtige Begriffe (Methoden, Technologien, Werkzeuge) rund um das Thema „Digitalisierung“

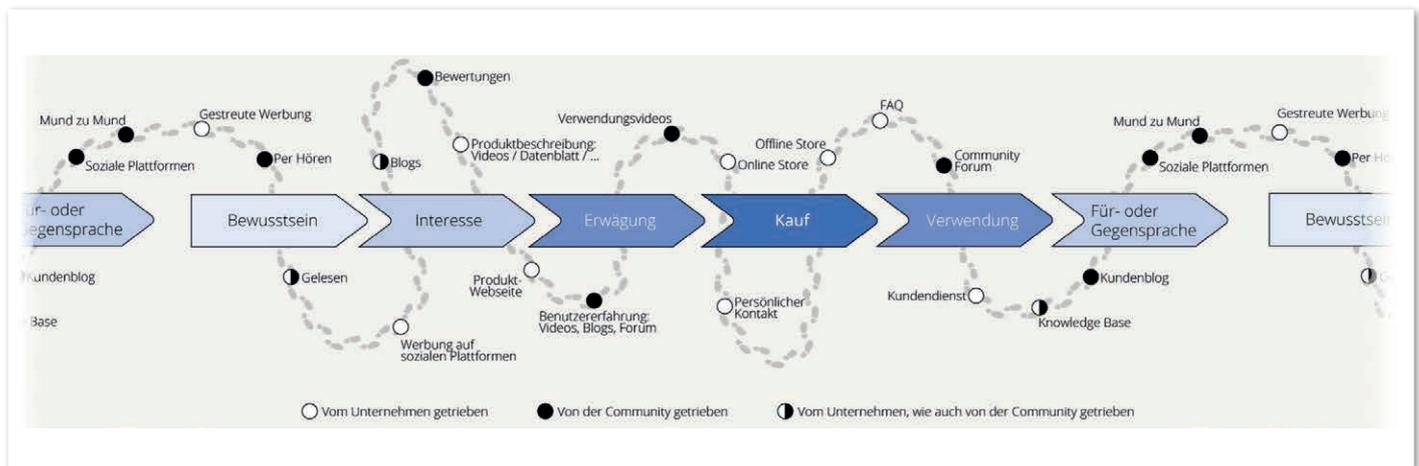


Abbildung 4: Der Weg des Kunden („Customer Journey“) von der Interessenbildung bis zum Für- oder Gegensprecher eines Angebots

Konkrete Handlungsfelder

Neben der Optimierung von Geschäftsprozessen ergibt sich aus all den angesprochenen Punkten eine Vielzahl möglicher Handlungsfelder. Einige Beispiele:

- Die Auswirkung der DT wird in Unternehmen noch immer unterschätzt. Zuerst ist daher das Schaffen eines Bewusstseins über die Auswirkung ein entscheidendes Handlungsfeld innerhalb des Unternehmens. Den Mitarbeitern innerhalb der Unternehmen muss klar werden, dass es Veränderungen in der Kultur und in der Art der Zusammenarbeit geben muss, damit das Unternehmen weiter erfolgreich sein kann, und dass diese Veränderungen nicht negativ sein müssen.
- Die veränderten Kundenerwartungen führen zu Veränderungen, wie mit Kunden kommuniziert wird, beziehungsweise wirken sich die Erwartungen über die Kommunikation (wie ständige Erreichbarkeit über verschiedene Kanäle) auf die Kundenbeziehung und deren Management aus. Dies führt zu weitreichenden Veränderungen im Kunden- und Community-Management, dem tiefere Beachtung geschenkt werden muss.
- Die IT nimmt eine besonders integrative Rolle ein. Fachabteilungen müssen übergreifend zusammenarbeiten und fachübergreifende Teams in die Lage versetzt werden, Änderungen durchzuführen, ohne dafür den traditionellen Berichtsweg zu gehen. Dies erfordert eine Neuausrichtung der Aufbau- und Ablauforganisation.

- Um die Potenziale der digitalen Technologien nutzen zu können, ist IT-Breitenwissen notwendig. Nicht unbedingt, um Projekte direkt im Haus realisieren zu können, sondern um nach vorne zu denken. Hier hilft der systematische Aufbau von IT-Breitenwissen, etwa durch das Fördern von berufsbegleitenden Fortbildungsmöglichkeiten für Mitarbeiter.
- Um die Kreativität der eigenen Mitarbeiter im Unternehmen nutzen zu können, bedarf es einer offenen und vertrauensvollen Unternehmenskultur und eines neuen Führungsstils.
- Das Neudenken des eigenen Geschäftsmodells oder Teilen davon wird zu einer wesentlichen Kompetenz der DT. Hierfür müssen die modernen Methoden der Geschäftsmodell-Entwicklung bekannt sein und angewendet werden.
- Eine von den Hidden-Champions weitreichend verwendete Taktik ist auch die enge Zusammenarbeit mit Hochschulen oder anderen Unternehmen. Technologie-Transfer stellt einen wichtigen Faktor dar, um neue Produkte und Dienstleistungen zu entwickeln beziehungsweise auch vorhandene Synergien mit anderen Unternehmen zu nutzen.

Fazit

Die DT stellt Unternehmen vor große Herausforderungen. Es bahnen sich weitreichende Veränderungen in der Aufbau- und Ablauforganisation von Unternehmen an. Hier gilt es nicht, eine Schablone zu finden und zu instanzen, die für alle Unternehmen gilt, sondern den eigenen Weg zu finden.

Literatur

- [1] T. Cole, Digitale Transformation, Warum die deutsche Wirtschaft gerade die digitale Zukunft verschläft und was jetzt getan werden muss!, Vahlen, 2015
- [2] Roland Berger, Die Digitale Transformation der Industrie, Bundesverband der Deutschen Industrie e.V., 2015
- [3] S. Hastie und S. Wojewoda, 2015: <https://www.infoq.com/articles/standish-chaos-2015>
- [4] K. Deimel und K. Heinrich, „Erfolgsfaktoren der Hidden Champions,“ 2009: http://www.uni-klu.ac.at/iug/downloads/Deimel_-_Erfolgsfaktoren_der_Hidden_Champions.pdf
- [5] F. Laloux und M. Kauschke, Reinventing Organizations, Ein Leitfaden zur Gestaltung sinnstiftender Formen der Zusammenarbeit, Vahlen, 2015
- [6] I. Dell, The Global Evolving Workforce Study, Expert Insights, Dell, Intel, 2014
- [7] U. Brandes, P. Gemmer, H. Koschek und L. Schlütke, Management Y, Agile, Scrum, Design Thinking & Co: So gelingt der Wandel zur attraktiven und zukunftsfähigen Organisation, Campus, 2014
- [8] D. Pink, Drive, The Surprising Truth About What Motivates Us, Canongate Books, 2011
- [9] B. Gloger und D. Rösner, Selbstorganisation braucht Führung: Die einfachen Geheimnisse agilen Managements, Hanser, 2014
- [10] C. Keese, Silicon Valley, Was aus dem mächtigsten Tal der Welt auf uns zukommt, Knaus, 2014
- [11] T. Sattelberger, I. Welpel und A. Boes, Das demokratische Unternehmen: Neue Arbeits- und Führungskultur im Zeitalter digitaler Wirtschaft, Haufe-Lexware, 2015
- [12] transformationswerke.de, „Transformationswerk Report 2016 – die größte bereichsübergreifende Studie zur digitalen Transformation der Wirtschaft“, 2016: <https://www.transformationswerk.de/studie>
- [13] R. T. Kreutzer und K.-H. Land, Digitaler Darwinismus: Der stille Angriff auf Ihr Geschäftsmodell und Ihre Marke, Springer, 2013

Dr. Thomas Kofler
thomas.kofler@zd-b.de



Neues Format „DOAG Meinungsforum“ setzt sich durch

Rolf Scheuch, Leiter DOAG Business Intelligence Community

Auf der DOAG Konferenz 2017 hat die DOAG BI Community ein neues Format unter dem Namen „DOAG Meinungsforum“ getestet und in der Folge auf der Konferenz drei Mal abgehalten. Thema war die Diskussion rund um das Spannungsfeld „BI/Data Warehouse vs. Big Data“.

Nach einer kurzen Einführung erfolgte im Meinungsforum die Diskussion durch die Teilnehmer selbst. Die Moderatoren führten kurz in die Fragestellung ein und inszenierten dies als kleines Schauspiel. Auf der einen Seite wurde die Sicht eines „Traditionalisten“ vertreten, ihm gegenüber stand der „Innovator“, der neue Ideen aufgriff. Die Argumente beider Seiten waren absichtlich etwas platt und bewusst schwarz-weiß, um die Standpunkte zu polarisieren und Angriffsfläche für die Diskussion zu bieten. Spannend war zu erleben, wie die Moderatoren, die alle erfahrene Berater sind, sich zurückhielten und die Teilnehmer ständig ins Spiel brachten.

Zu Beginn war man seitens der BI Community unsicher, ob dieses Format in der Form akzeptiert werden würde. Die Teil-

nehmerzahlen haben sich jedoch von Mal zu Mal gesteigert: von 16 über 27 bis auf 41 auf dem letzten Meinungsforum. Das hat positiv überrascht. Jedoch ist der allgemeine Kenntnisstand zu Big Data nicht so hoch wie erwartet. Viele Teilnehmer haben eine grundlegende Idee, sodass die Diskussion von wenigen Teilnehmern, aber dafür leidenschaftlich geführt wurde. Hier wird die BI Community einige Angebote zu machen haben, um das Wissen um Big Data auszubauen.

Das erfolgreiche Format des Meinungsforums wurde im Dezember in die Regionalgruppe Berlin-Brandenburg getragen. Etwa 40 Teilnehmer diskutierten das Spannungsfeld Bi und Big Data. Aus gegebenem Anlass war „post-faktisch“ das Leitmotiv, sodass die

Diskussion sehr kurzweilig und durch allerlei klare, politisch unkorrekte Aussagen belebt wurde. Gerne wiederholen die Moderatoren dies als Gäste auf anderen Regionaltreffen. An dieser Stelle noch ein großes Danke an Alfred Schlaucher und Björn Ständer von Oracle, die beim Meinungsforum tatkräftig unterstützt haben, sowohl auf dem Podium wie auch als Ansprechpartner während der Diskussion, um spezifische Oracle-Fragen unmittelbar beantworten zu können.

Rolf Scheuch
rolf.scheuch@doag.org

Alles, was die SAP-COMMUNITY wissen muss,
finden Sie monatlich im E-3 MAGAZIN.

Ihr WISSENSVORSPRUNG im Web, auf iOS und Android
sowie PDF und Print: e-3.de/abo

Wer nichts
weiß,
muss alles
glauben!

Marie von Ebner-Eschenbach



SAP® ist eine eingetragene Marke der SAP AG in Deutschland und in den anderen Ländern weltweit.

www.e-3.de

A large circular graphic composed of dark blue silhouettes of various logistics-related elements: trucks, airplanes, and a ship. The central area of the circle is a solid dark blue field containing white text and a QR code. The background is a light, textured grey.

DOAG 2017

Logistik + IT

20. Juni 2017 in Hamburg



logistik.doag.org