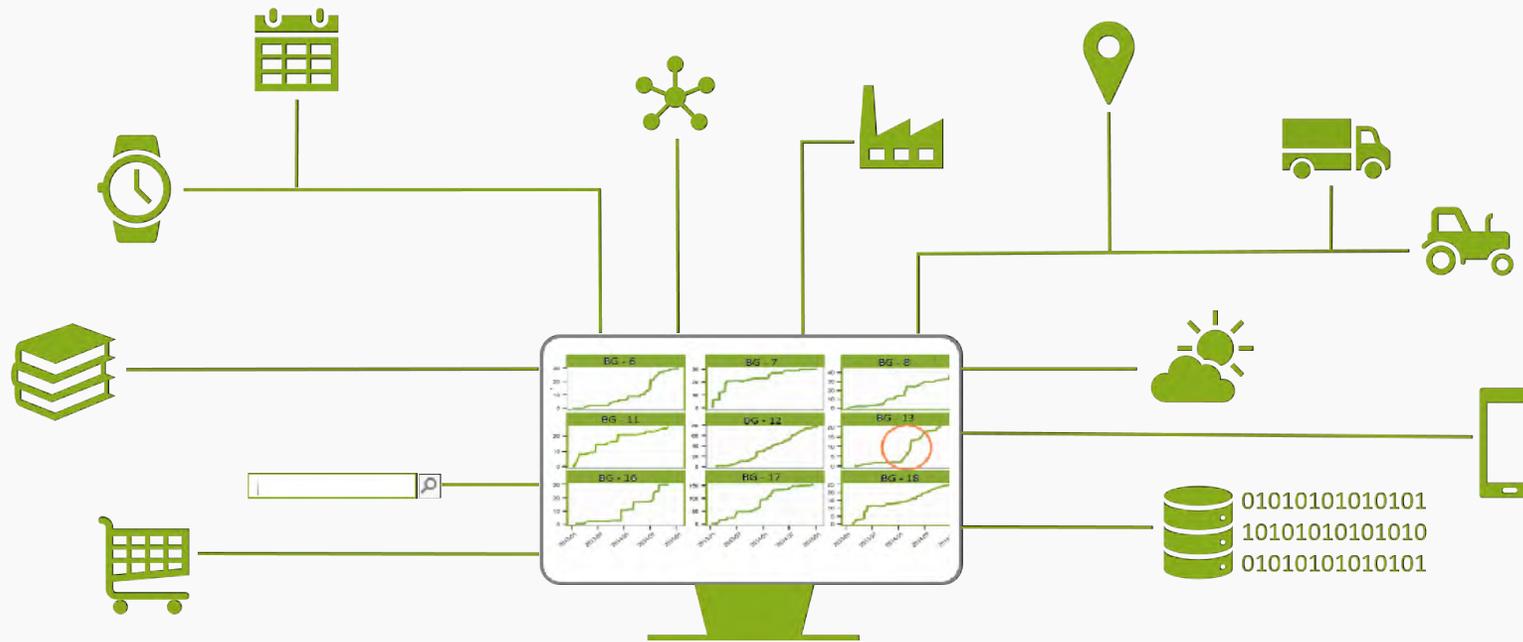




Die Data Science Spezialisten.



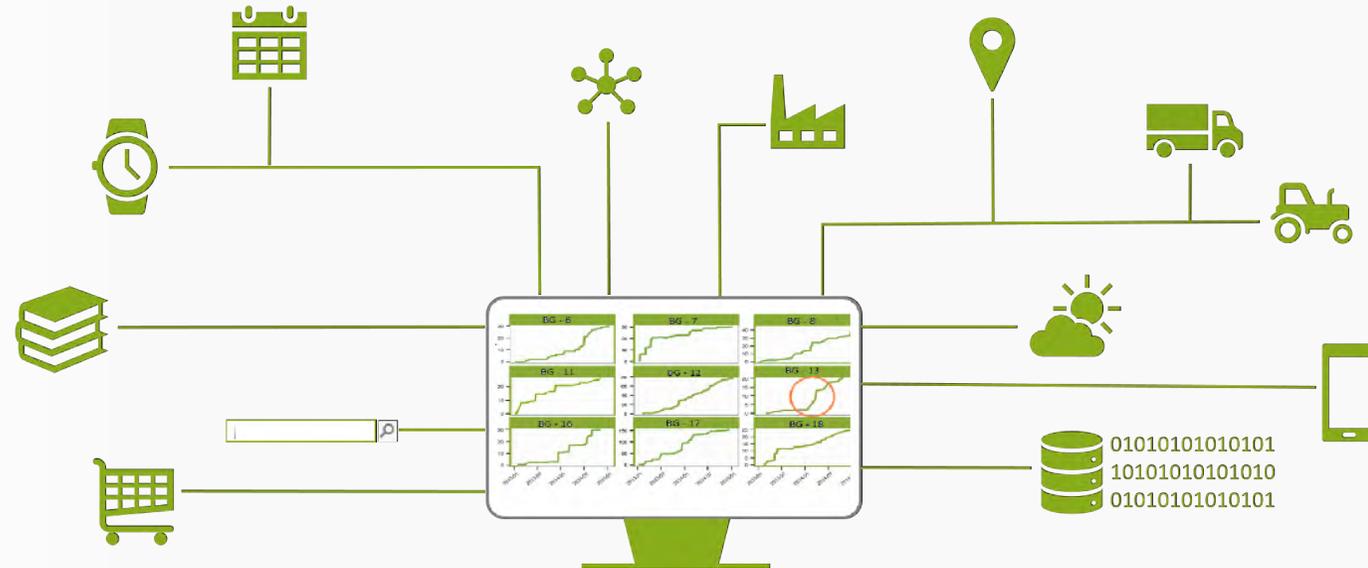
Oliver Bracht
Chief Data Scientist

Data Science, Künstliche Intelligenz und Machine Learning:
Wie hebe ich den Datenschatz?

HESSENMETALL

Agenda

- Über uns
- Was ist Data Science?
- Was kann Data Science?
- Was braucht Data Science?
- Was sind die Erfolgsfaktoren?
- Was sind die Anwendungsfälle?



Über uns

- Gegründet Anfang 2010
- Interdisziplinäres Team
- 50 Mitarbeiter
- Inhabergeführt

Facts

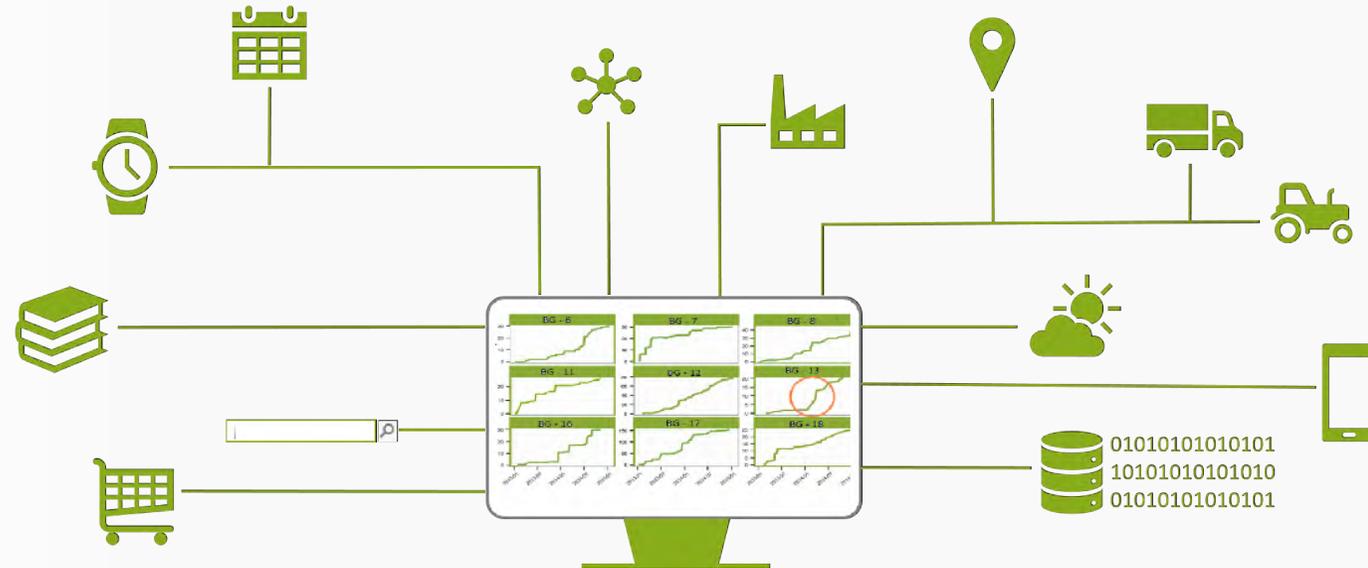


Mission

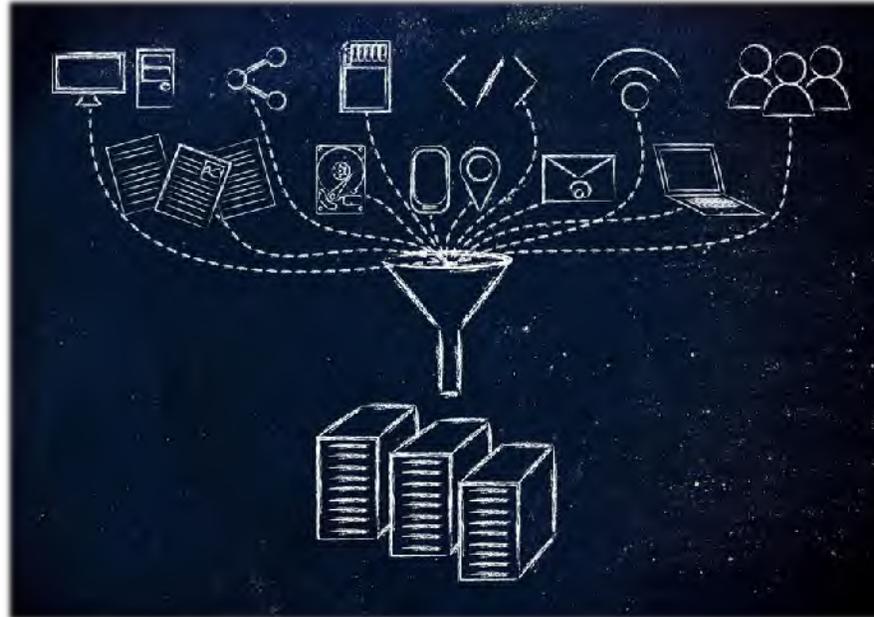
- Entwicklung von Analyse- und Prognosemodellen
- Evidenzbasierte Management Summaries
- Data-Science-Enablement
- Operationalisierung von Data Science

Agenda

- Über uns
- **Was ist Data Science?**
- Was kann Data Science?
- Was braucht Data Science?
- Was sind die Erfolgsfaktoren?
- Was sind die Anwendungsfälle?



daten

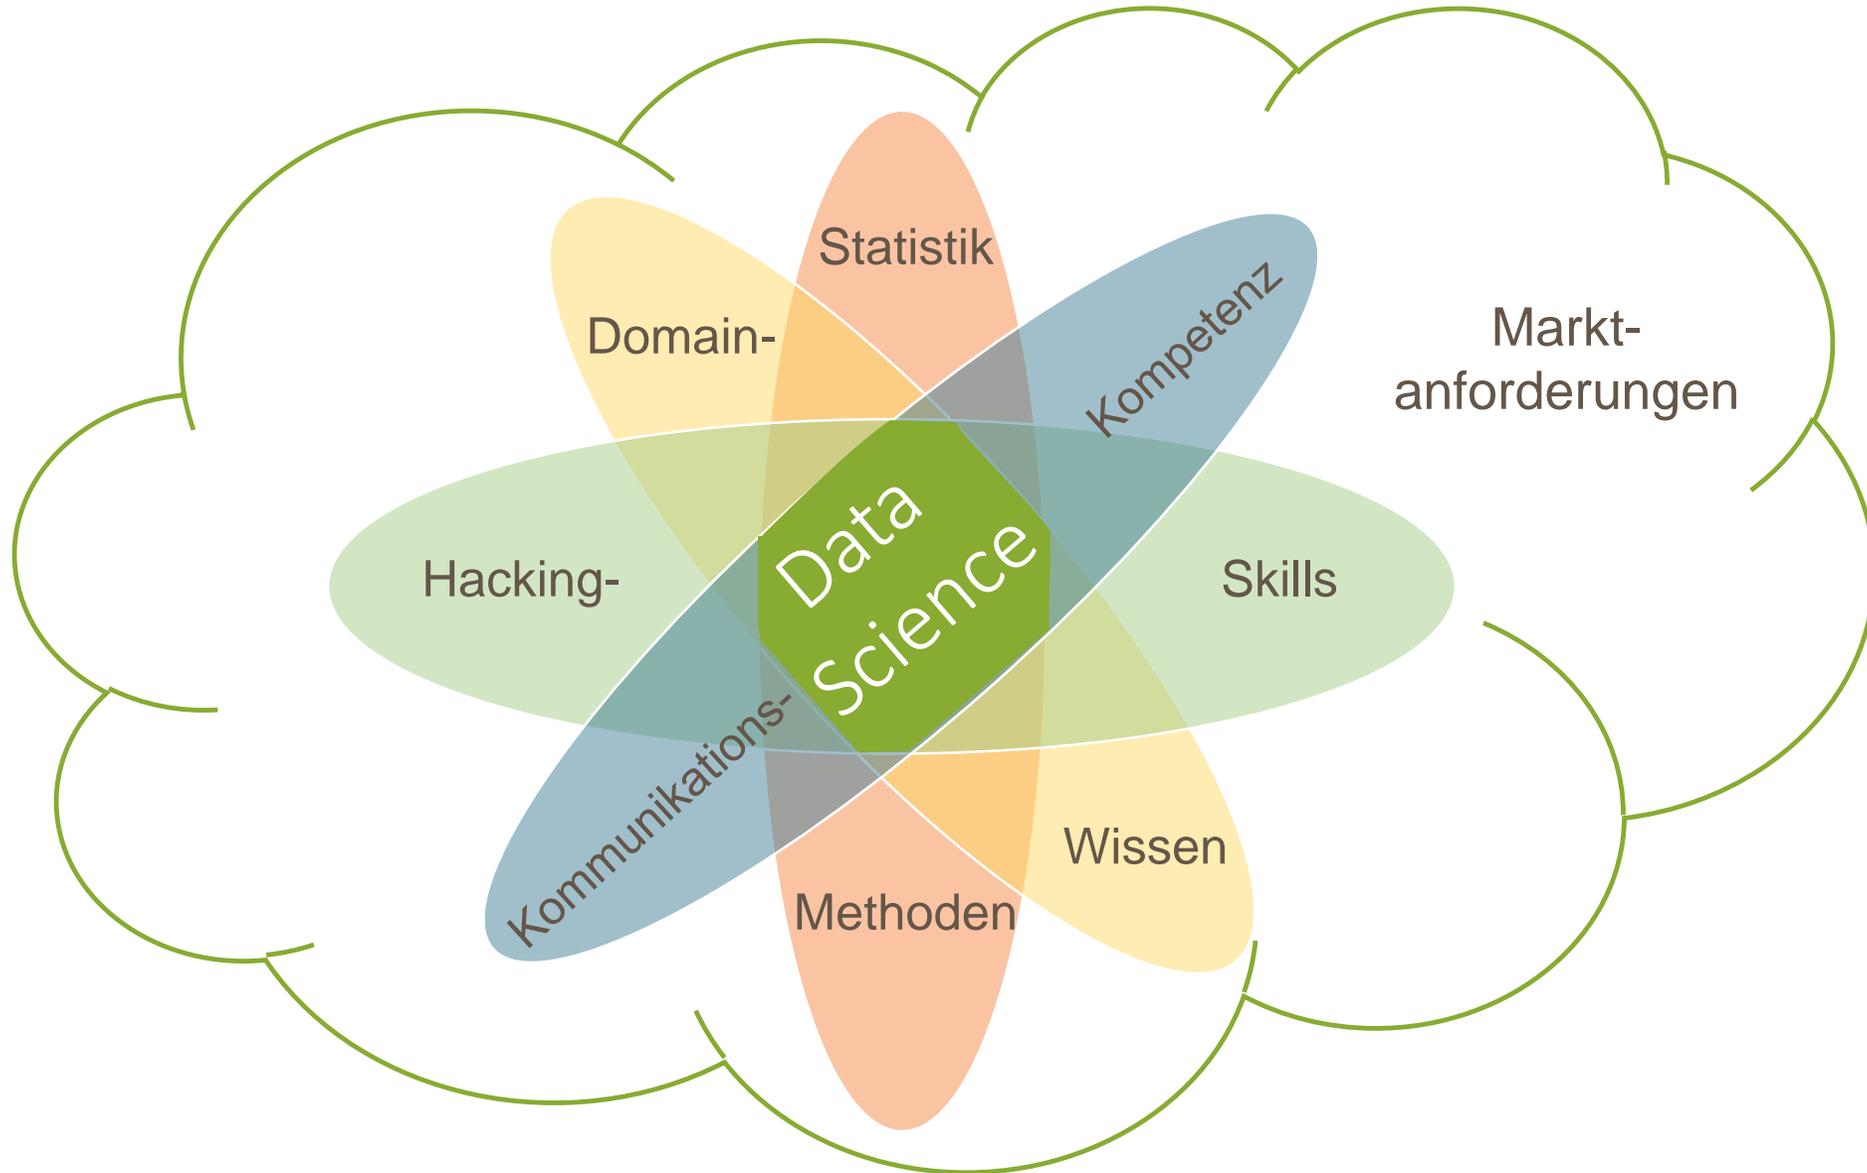


daten ► wissen



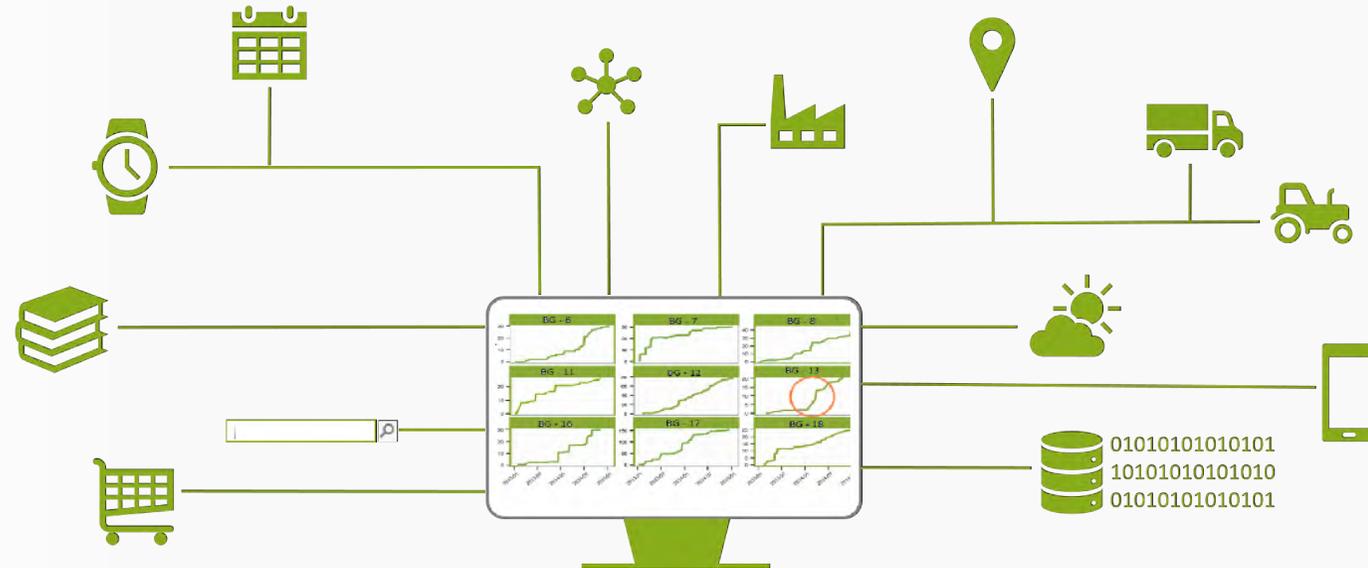
daten ► wissen ► nutzen





Agenda

- Über uns
- Was ist Data Science?
- **Was kann Data Science?**
- Was braucht Data Science?
- Was sind die Erfolgsfaktoren?
- Was sind die Anwendungsfälle?



Was kann Data Science?

Entscheidung

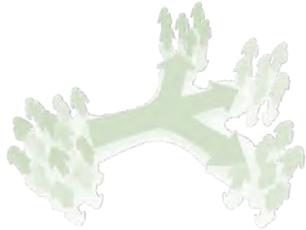
Was kann Data Science?

Entscheidung



Was kann Data Science?

Entscheidung



Was kann Data Science?

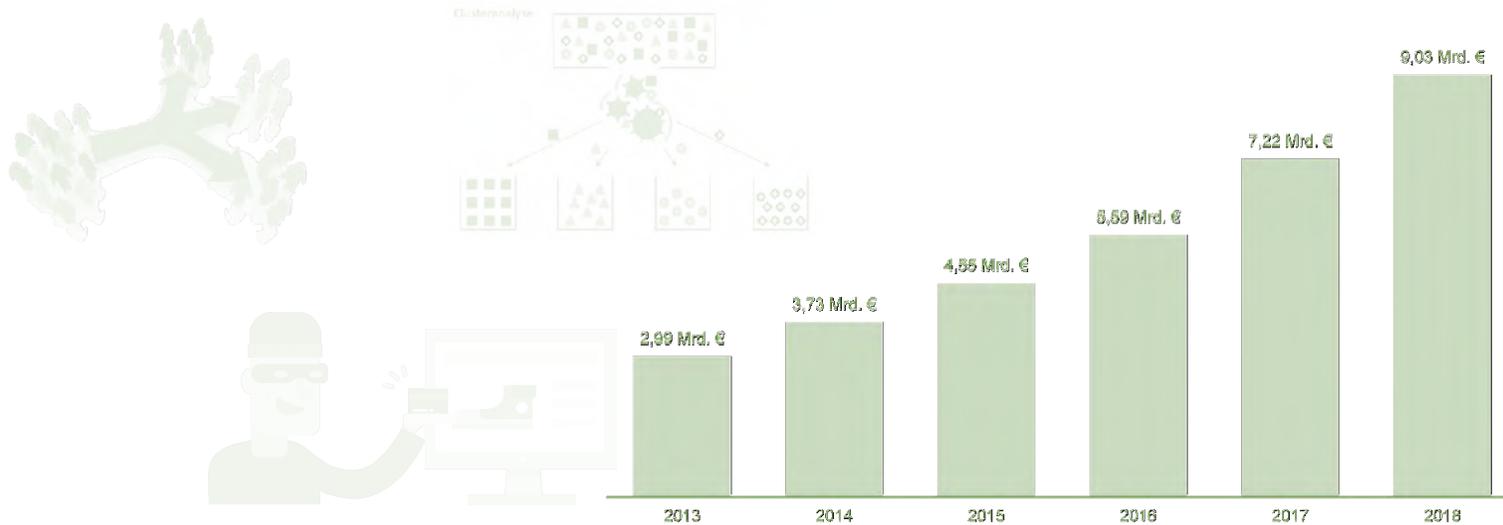
Entscheidung



Was kann Data Science?

Entscheidung

Prognose



Was kann Data Science?

Entscheidung



Prognose



Was kann Data Science?

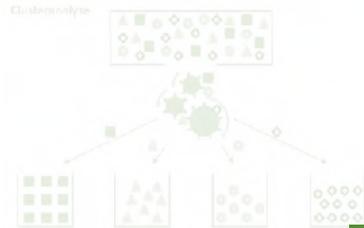
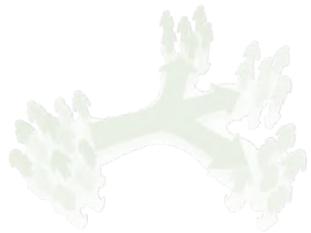
Entscheidung

Prognose



Was kann Data Science?

Entscheidung



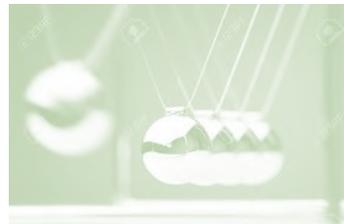
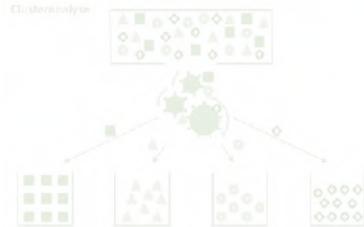
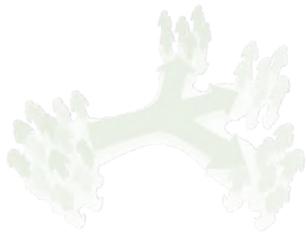
Prognose



Ursache-Wirkung

Was kann Data Science?

Entscheidung



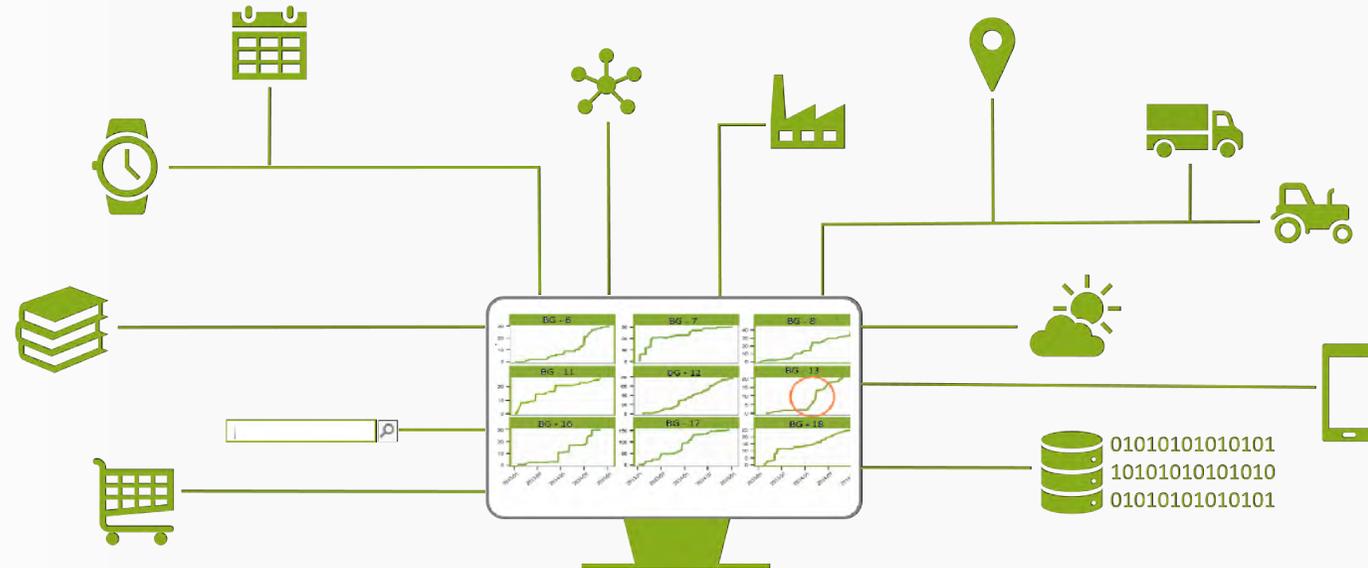
Prognose



Ursache-Wirkung

Agenda

- Über uns
- Was ist Data Science?
- Was kann Data Science?
- **Was braucht Data Science?**
- Was sind die Erfolgsfaktoren?
- Was sind die Anwendungsfälle?



Was braucht Data Science?

Daten ...

... müssen vorhanden sein



Was braucht Data Science?

Daten ...

... müssen vorhanden sein



Was braucht Data Science?

Daten ...

... müssen vorhanden sein



... sollten relevant sein



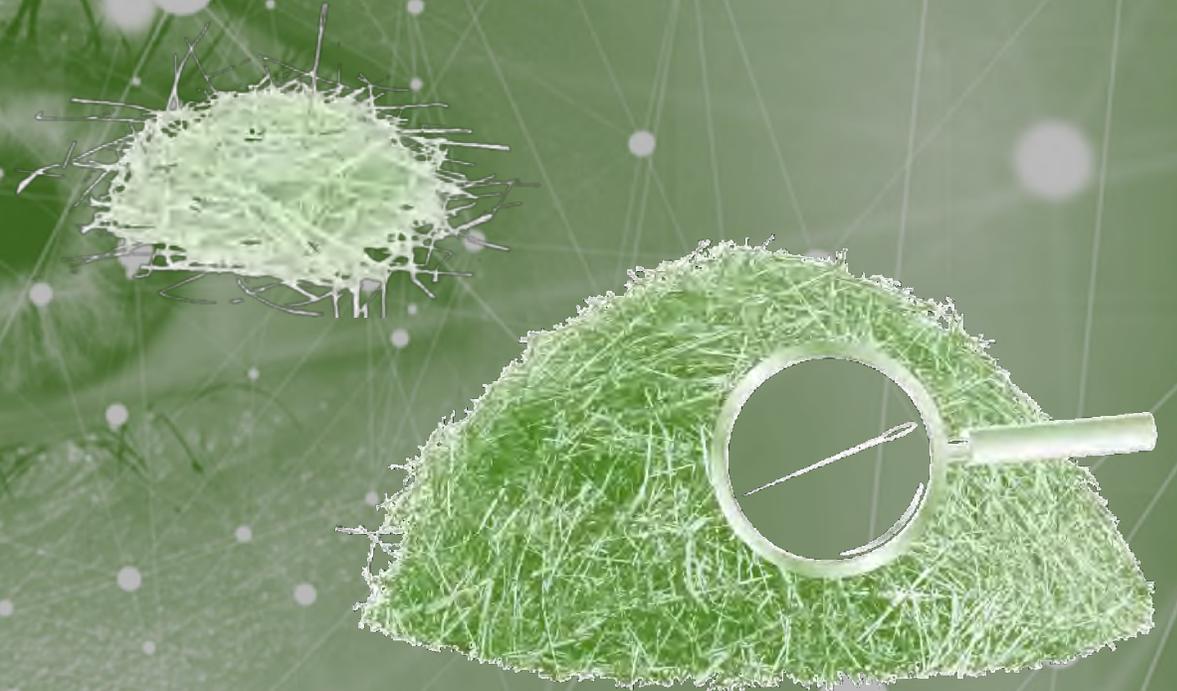
Was braucht Data Science?

Daten ...

... müssen vorhanden sein



... sollten relevant sein



Was braucht Data Science?

There are known knowns; there are things we know we know. We also know there are known unknowns; that is to say we know there are some things we do not know. But there are also unknown unknowns - the ones we don't know we don't know.

Donald Rumsfeld



Was braucht Data Science?



Was braucht Data Science?

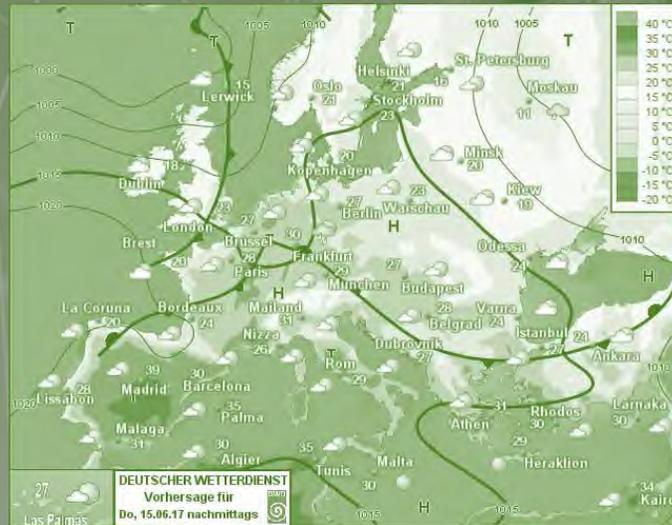
Informationsdichte



Was braucht Data Science?

Lösbare Anwendungsfälle

komplex



kompliziert



Was braucht Data Science?

(Gute) Indikatoren



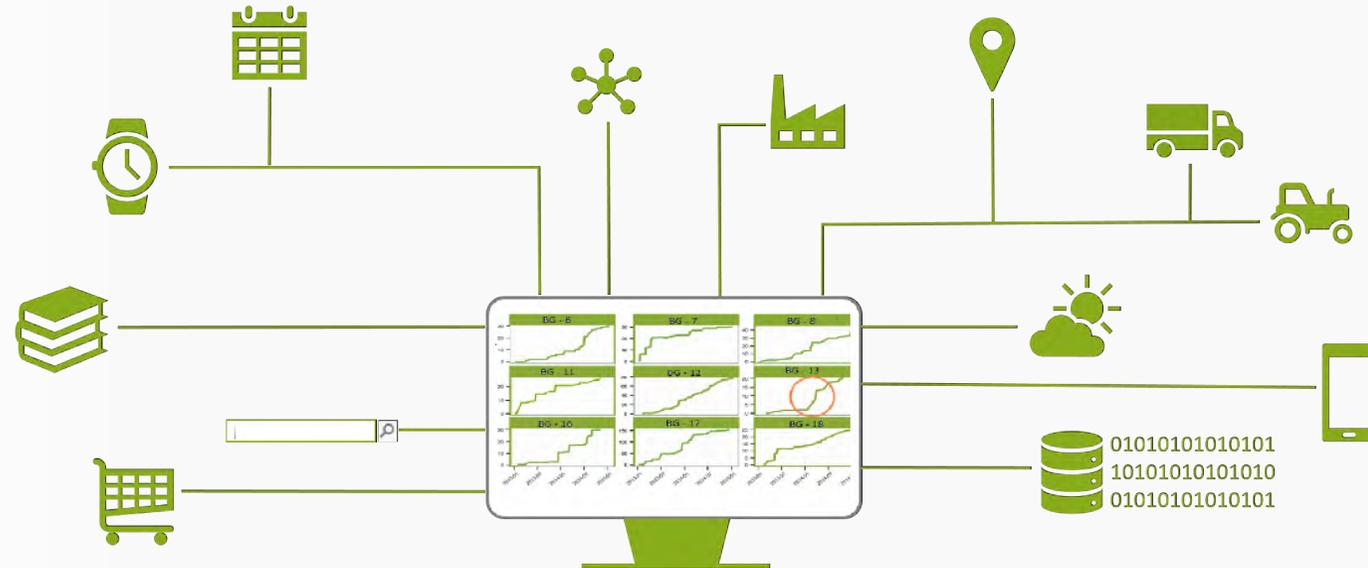
Was braucht Data Science?

Gute Indikatoren



Agenda

- Über uns
- Was ist Data Science?
- Was kann Data Science?
- Was braucht Data Science?
- **Was sind die Erfolgsfaktoren?**
- Was sind die Anwendungsfälle?



Die Erfolgsfaktoren von Data Science

Der Einstieg
Bottom-up statt Top-down



Die Erfolgsfaktoren von Data Science

Das Team
Interdisziplinär



Die Erfolgsfaktoren von Data Science

Die Daten

Verfügbarkeit, der für den Use Case relevanten Informationen



Die Erfolgsfaktoren von Data Science

Das Toolset
Im Kern Open Source



Die Erfolgsfaktoren von Data Science

Die Analysemethoden

Der große Methodenkoffer statt
„One-Algo-fits-all“



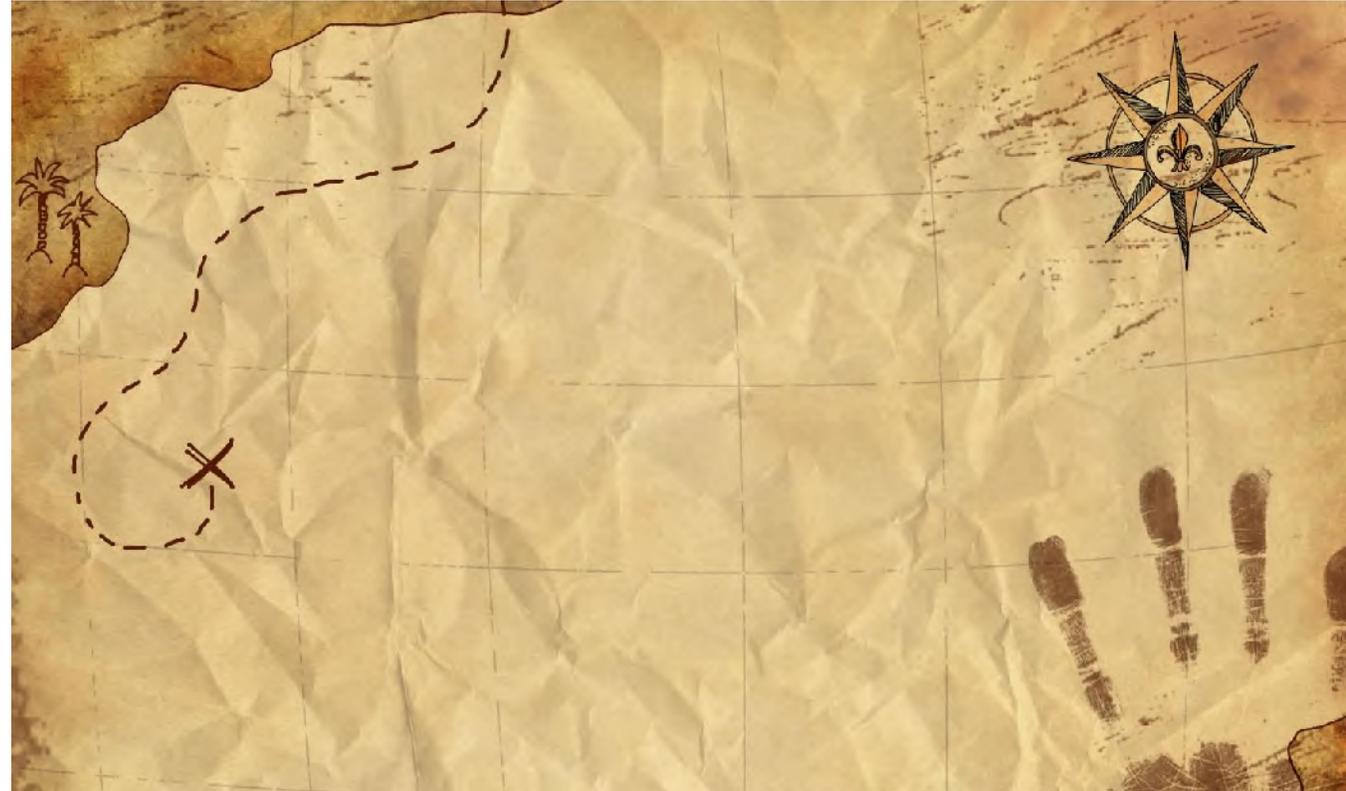
Die Erfolgsfaktoren von Data Science

Die Erwartungshaltung
Chancen erkennen, aber keine
Wunder erwarten



Die Erfolgsfaktoren von Data Science

Der Projektverlauf
Akzeptanz für eine
Entdeckungsreise



Die Erfolgsfaktoren von Data Science

Die Projektanlage
Think big – start small



Die Erfolgsfaktoren von Data Science

Die Fachabteilungen
Mitnehmen und einbinden



Die Erfolgsfaktoren von Data Science

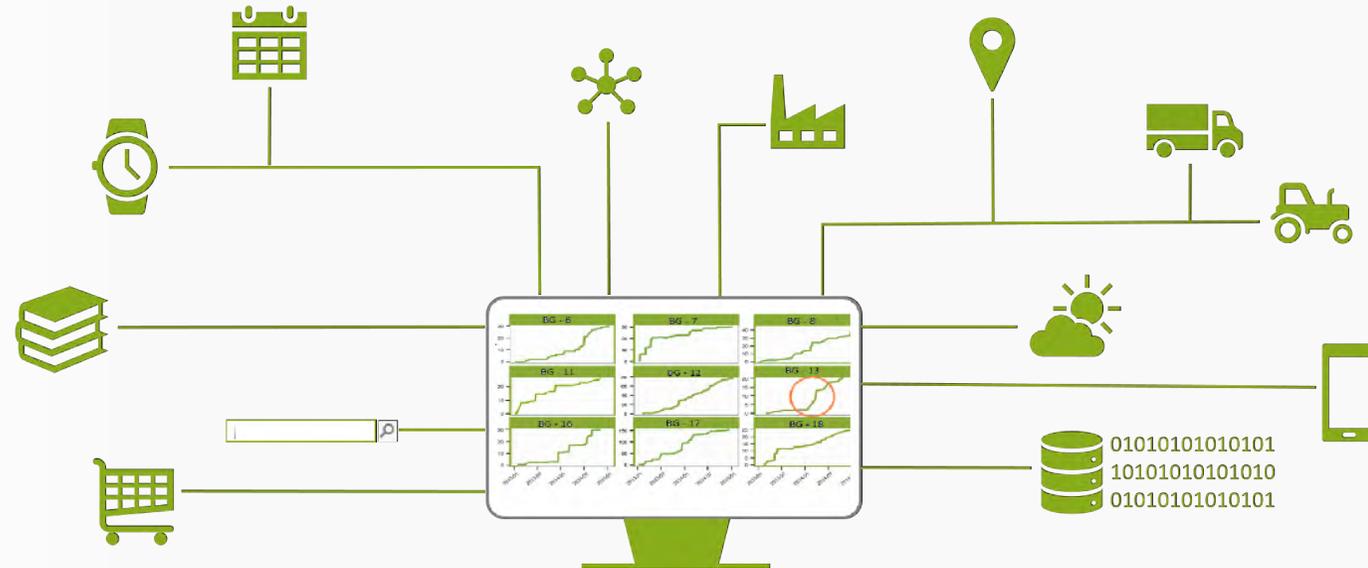
Die Kommunikation

Verständliche Botschaften und
Empathie statt Statistik-Kauderwelsch



Agenda

- Über uns
- Was ist Data Science?
- Was kann Data Science?
- Was braucht Data Science?
- Was sind die Erfolgsfaktoren?
- **Was sind die Anwendungsfälle?**



Predictive Maintenance in der Prozessfertigung



Predictive Maintenance in der Prozessfertigung

Ausgangssituation

- Prozessfertigung, Automobil Zulieferer,
- Wettbewerb und gestiegene Energiepreise, geringe Margen
- Bei bestimmten Maschinen-Ausfällen, muss die Anlage prozessbedingt über einen Tag runter und wieder hoch gefahren werden
- Hypothesen der Fachabteilung
 - Verschiedene Varianten laufen schlechter
 - Unterschied zwischen Tag- und Nachtschicht

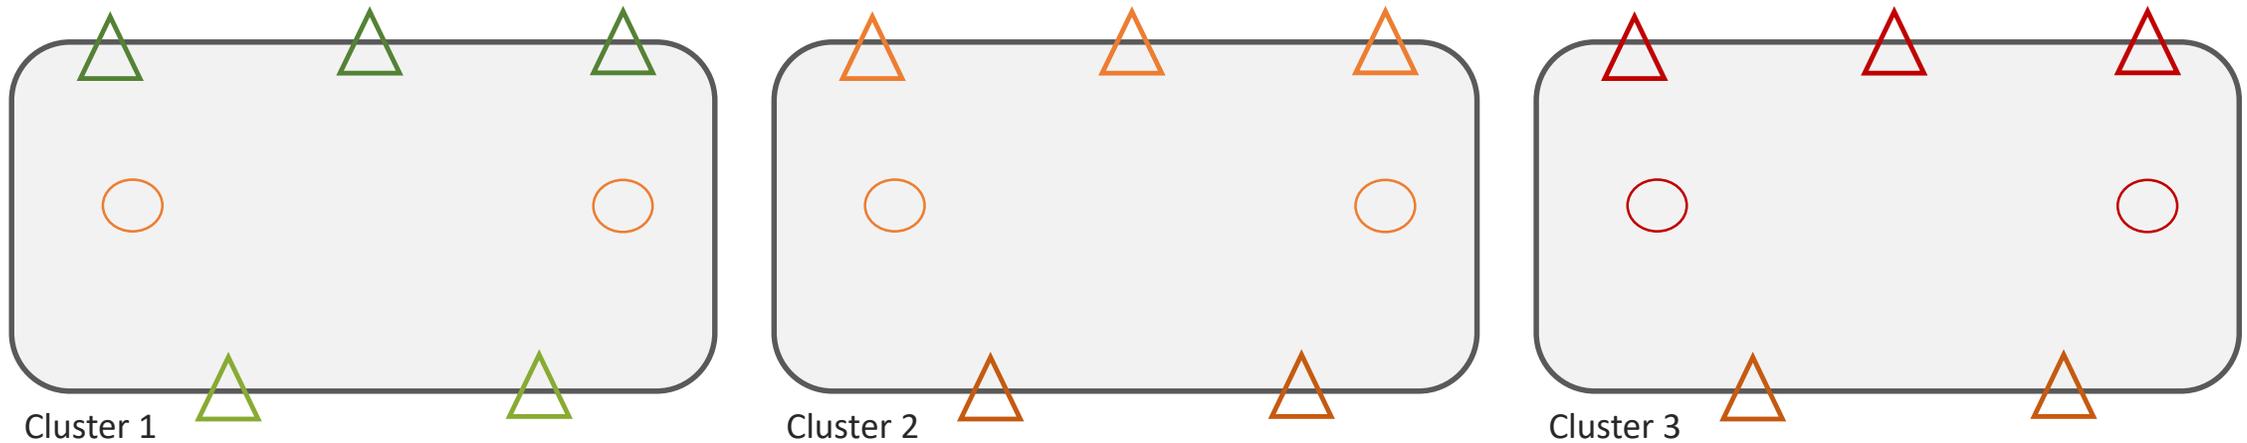
Datengrundlage

- 100 GB Sensordaten



Predictive Maintenance in der Prozessfertigung

Phase 1: Clusteranalyse



Messergebnisse

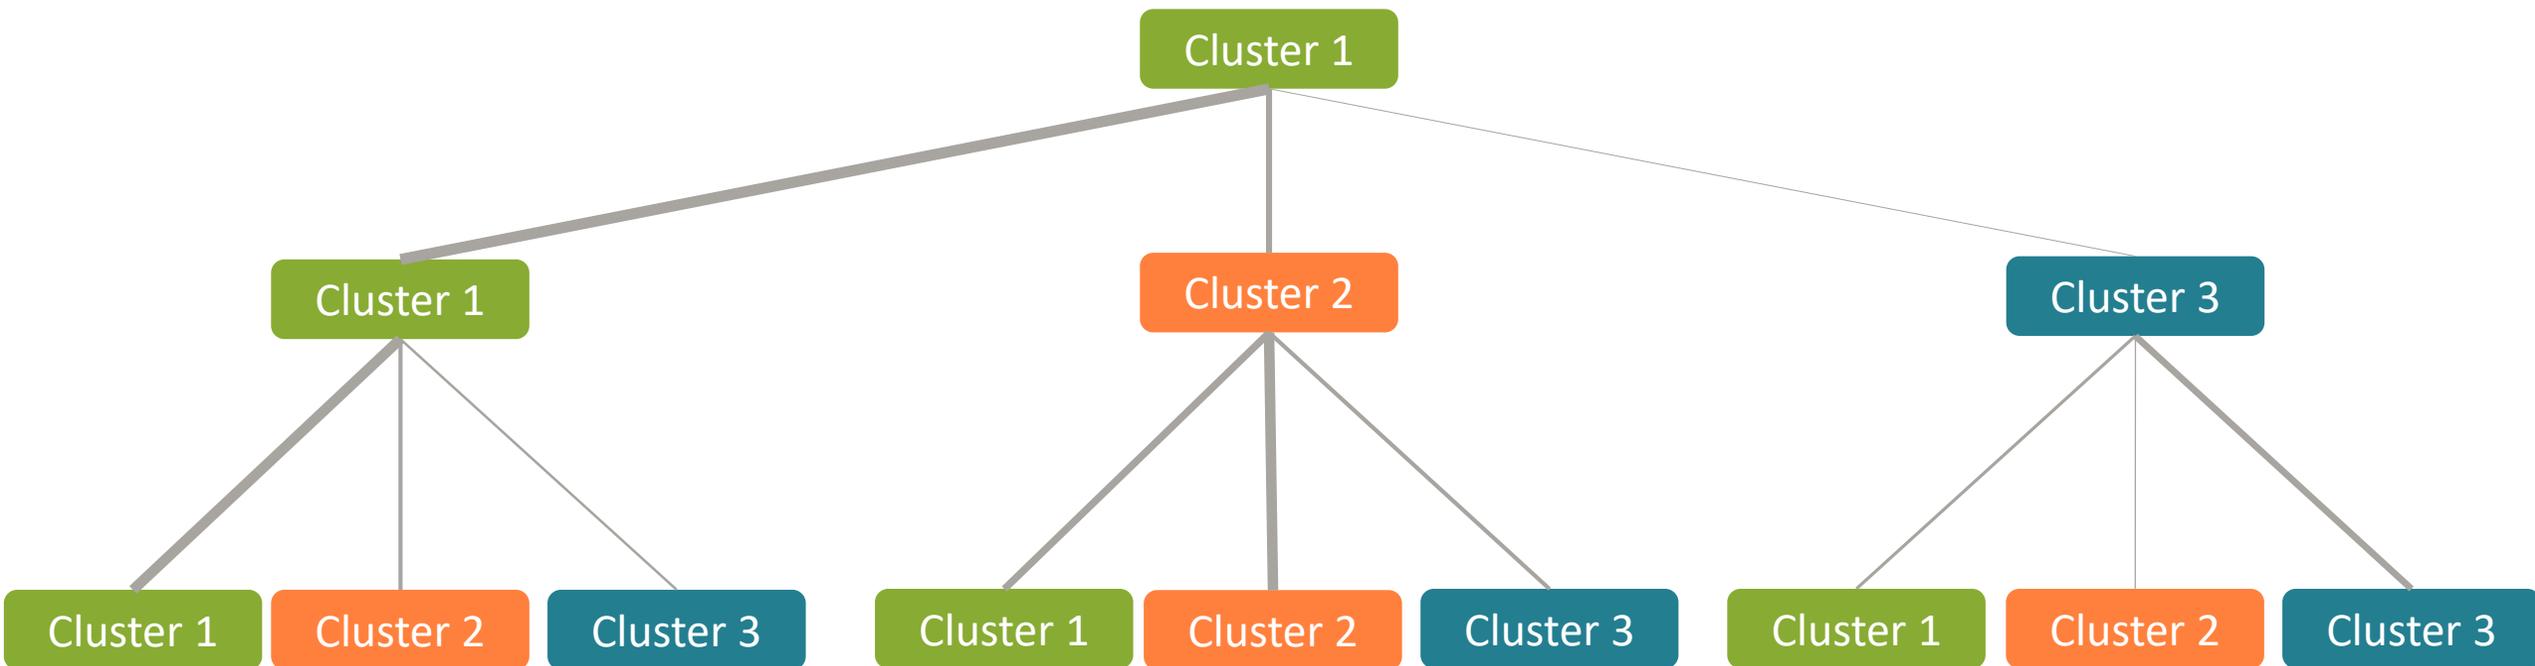


 Messpunkte Rahmen

 Messpunkte Fläche

Predictive Maintenance in der Prozessfertigung

Phase 2: Data-Mining-Model zur Anomalieerkennung

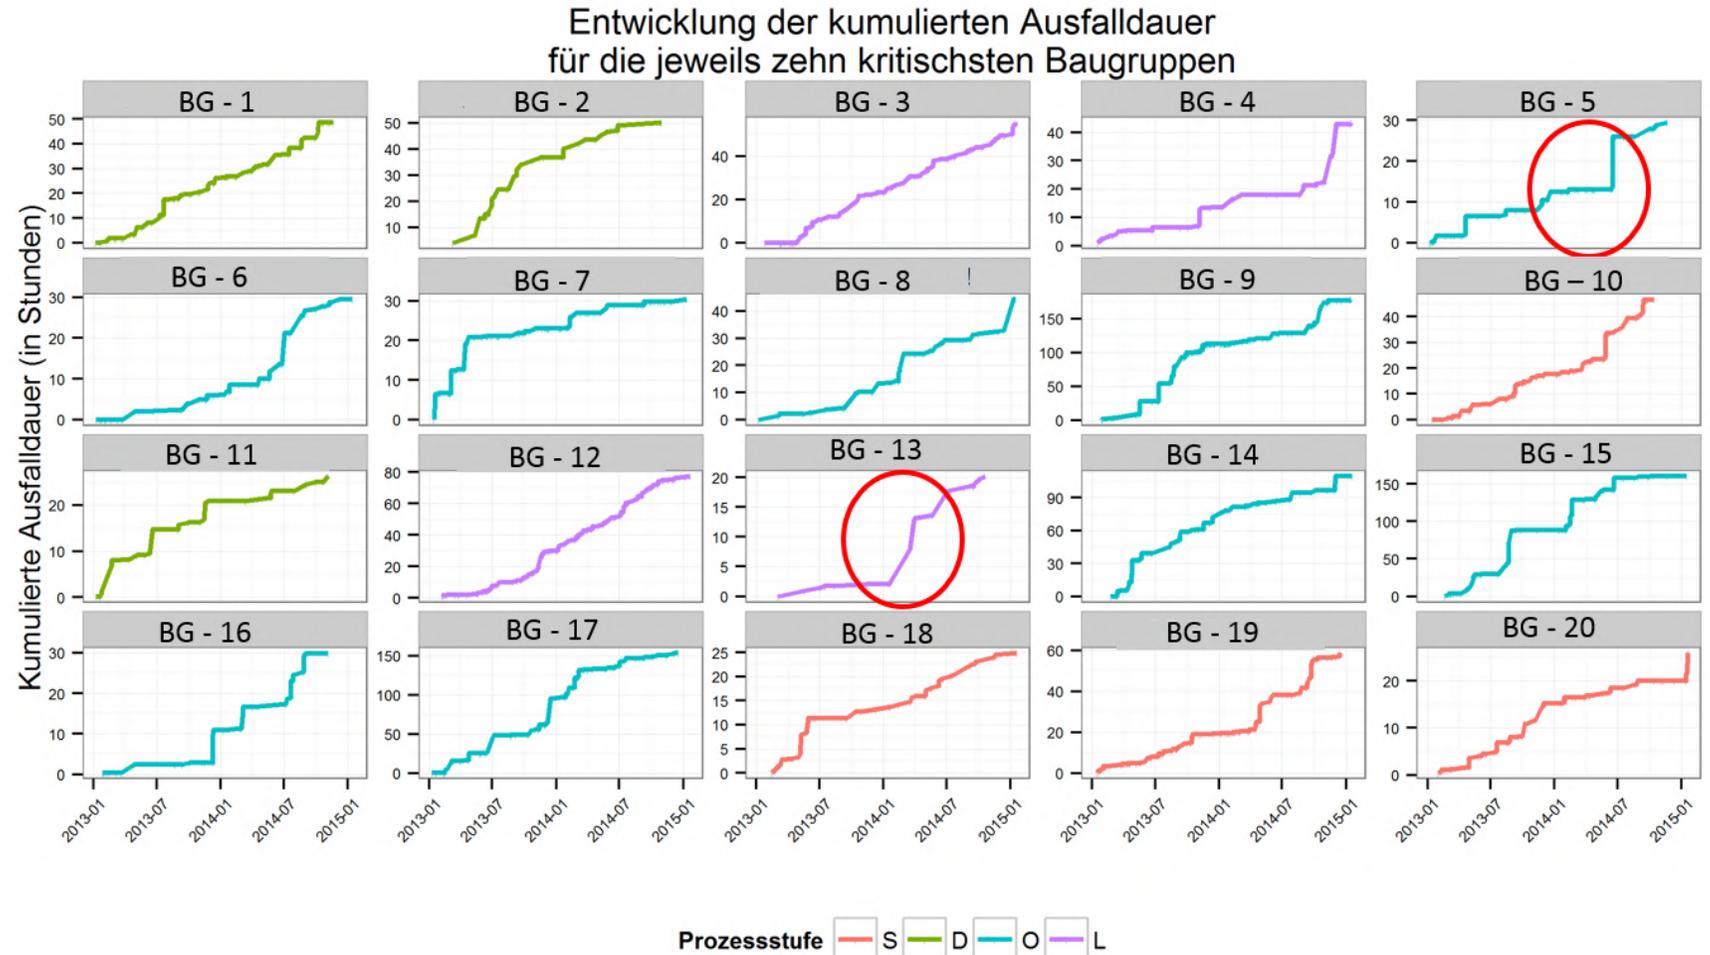


Abfolgen, die eine Warnung an den Maschinenführer auslösen:

C1 – C2 – C3 | C1 – C3 – C2

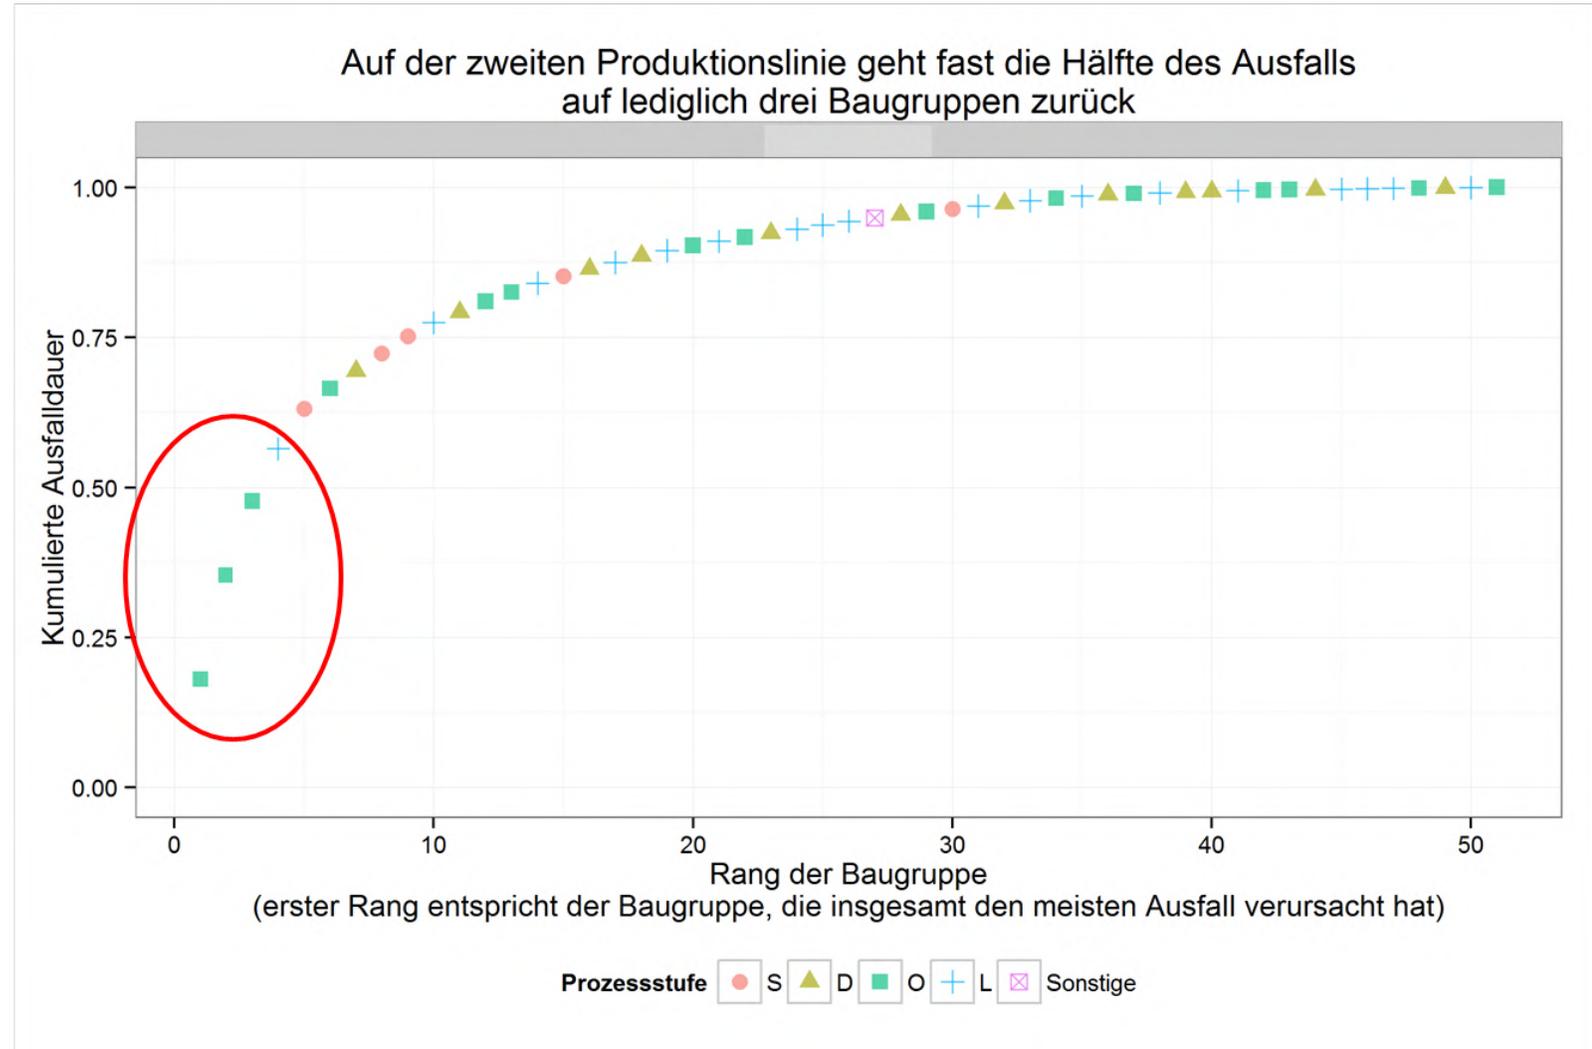
Predictive Maintenance in der Prozessfertigung

Anschauliche
deskriptive
Visualisierung



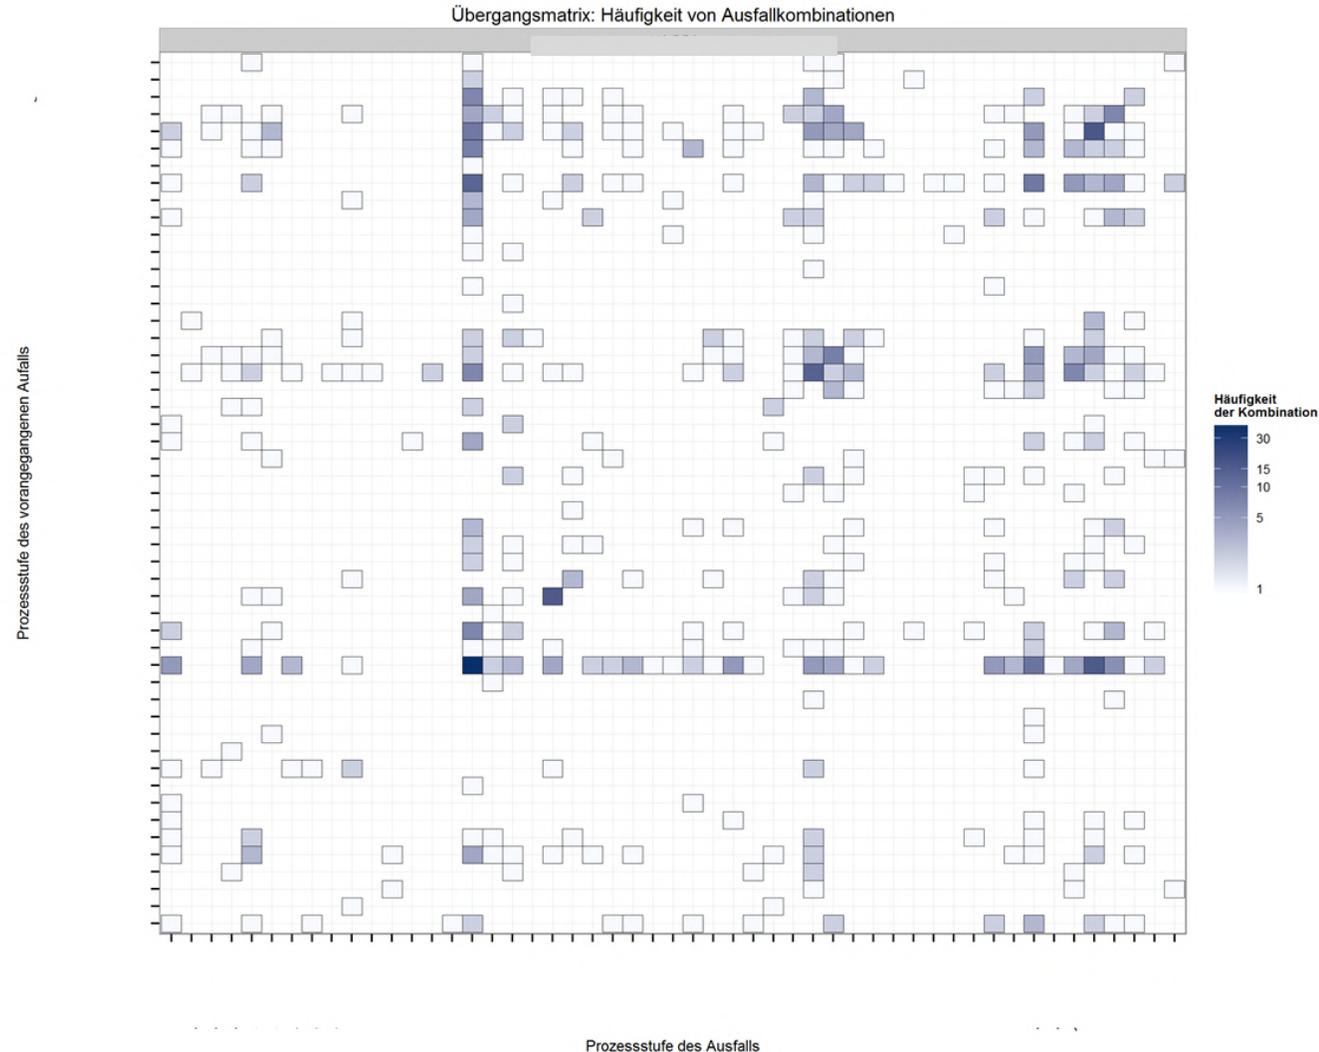
Predictive Maintenance in der Prozessfertigung

Beobachtung der kumulierten Ausfalldauer



Predictive Maintenance in der Prozessfertigung

Beobachtung von
Ausfallkombinationen



Korrelation zwischen den Ausfällen verschiedener Baugruppen (z.B.: Baugruppe 5 und 8) verursacht unter anderem durch die Auswirkungen von Reparaturarbeiten

Predictive Maintenance in der Prozessfertigung

Ergebnis

- Einige Hypothesen („Fehler passieren in der Nachtschicht“) konnten nicht bestätigt werden
 - Neue Muster wie die Ausfallkombinationen wurden erkannt
 - Gewonnene Erkenntnisse:
 - Allein die Verbesserung der Instandhaltung auf Basis der Erkenntnisse, könnte zu einem **50fachen ROI** führen!
 - Bestimmte Prozessstufen müssen um Sensoren erweitert werden
- Erkenntnis fließt in die nächste Entwicklung ein.

Lagerbestandsoptimierung für Ersatzteilhändler



Lagerbestandsoptimierung für Ersatzteilhändler

Ausgangssituation

- Sehr heterogenes und breites Sortiment
- Händler hat keine ausreichenden Informationen über den zukünftigen Absatz
- Absatz unterliegt größeren saisonalen Schwankungen und äußeren Einflüssen
 - Out-of-Stock-Situationen für einzelne Teile
 - Hohe Kapitalbindung durch lange Lagerzeit unvorhergesehen weniger nachgefragter Teile

Datengrundlage

- Daten aus dem historischen Absatz auf Kunden- und Artikelebene
 - Absatzmenge und –zeitpunkt
 - Kaufverhalten der Kunden im Zeitverlauf
 - Informationen über Out-of-Stock Situationen & lange Lagerzeiten

Lagerbestandsoptimierung für Ersatzteilhändler

Lösung

- Einsatz von Verfahren aus dem Gebiet der Zeitreihenanalysen zur Identifikation der saisonalen Schwankungen
- Regressionsmodelle zur Erkennung von Zusammenhängen
 - Zwischen den einzelnen Sortimentsbestandteilen
 - Zwischen äußeren Rahmenbedingungen und dem Kundenverhalten
- Poisson-Verteilung zur Modellierung der Abverkäufe in einem bestimmten Zeitfenster

Ergebnis

- Verlässliche Kenntnis der zukünftigen Absatzmengen auf Basis von Algorithmen
- Belastbare Entscheidungsgrundlage für die Steuerung der Beschaffungsprozesse
- Weniger Out-of-Stock Situationen und kürzere Durchlaufzeiten
- Grundlage für weitere Use Cases: z.B. Logistikprozesse

Analyse der Erfolgsfaktoren von Einzelhandelsfilialen



Analyse der Erfolgsfaktoren von Einzelhandelsfilialen

Ausgangssituation

- Welche Faktoren bzw. Faktorkombinationen beeinflussen den Erfolg einer Filiale?
- Was unterscheidet einen erfolgreichen von einem weniger erfolgreichen Markt?

Datengrundlage

- Informationen über die KPIs
- Eigenschaften der Märkte (Umsatz, Durchschnittsbon, Warenbestand etc.)
- Informationen über die Region (Raumart, Mietspiegel etc.)
- Informationen über die Kunden (Alter, Geschlecht etc.)
- Herausforderung: Relativ wenige Fälle stehen vielen Variablen gegenüber

Analyse der Erfolgsfaktoren von Einzelhandelsfilialen

Lösung

- Unterstützung des Kunden von der Datenaufbereitung über die Modellentwicklung bis hin zur Ableitung von Handlungsempfehlungen
- Durchführung eines Resampling
- Einsatz von Random-Forest-Modellen und Bayes-Ansätzen
 - Besonders robust im Bereich „Small Data“

Ergebnis

- Einschätzung darüber, welche Faktorenkombinationen die optimale Grundlage für die Errichtung neuer Filialen sind
- Wissensbasis für die Standortplanung und die Bewertung bestehender Filialen

Wie erschließen Sie das Potenzial Ihrer Daten?
Erfahren Sie noch mehr zum Thema.



Data Understanding
Kompetenzen
Agilität Kommunikation
Use Cases Projektteam
Analyse Dokumentation
Infrastruktur Modellierung

In unserer **Mediathek** finden Sie interessante
Case Studies und **Whitepaper**.

<https://www.eoda.de/de/mediathek.html>





Die Data Science Spezialisten.

eoda GmbH

Universitätsplatz 12

34127 Kassel

www.eoda.de

sales@eoda.de

+49 561 202724-51



[@eodaGmbH](#)



blog.eoda.de



[@eodaGmbH](#)



[eoda GmbH](#)