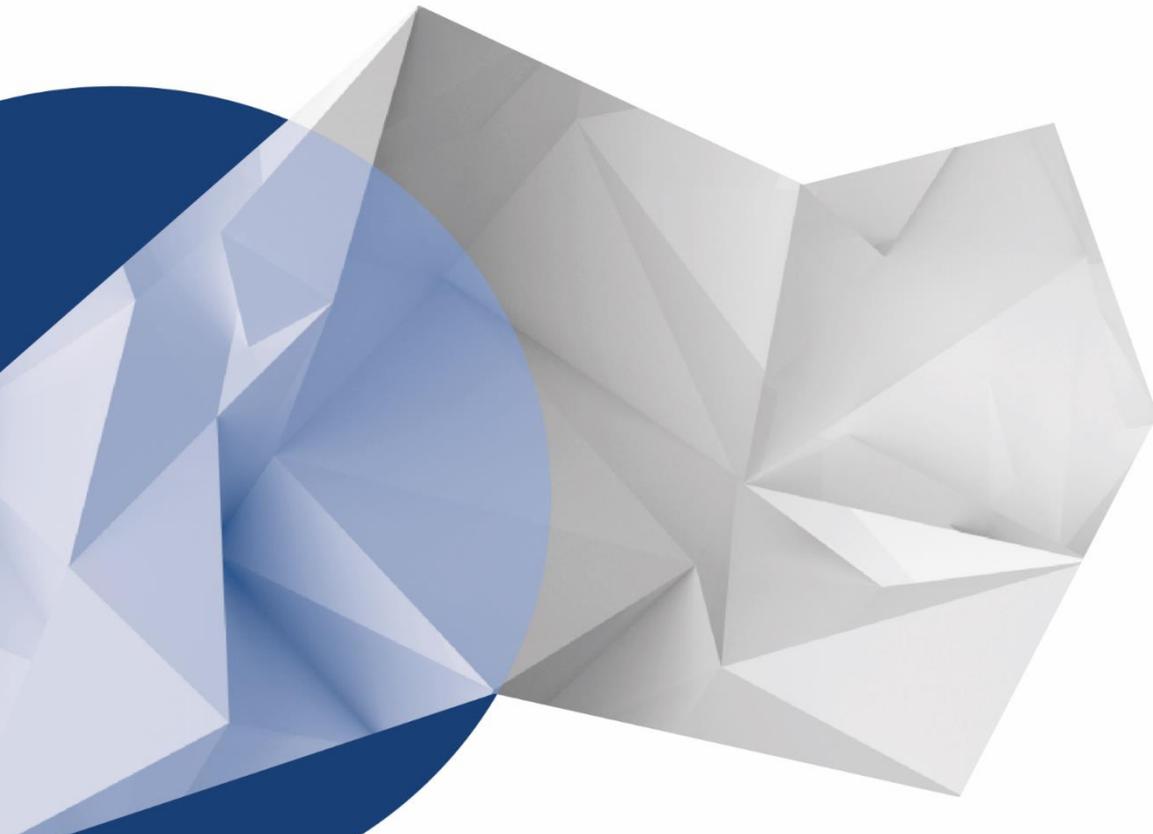


# DATA SCIENCE ALS WETTBEWERBSVORTEIL

Use Case Sprint – Das systematische Vorgehen zur Identifizierung und Umsetzung von Data Science Use Cases & Potenzialen



TCW



KILAB



# EXECUTIVE SUMMARY



Mit dem Einsatz von Data Science können Unternehmen **vielseitige Potenziale** in den unterschiedlichsten Bereichen entfalten. Die systematische Identifikation und die Erstellung von Proof-of-Concepts für vielversprechende Anwendungsfälle stellen Unternehmen häufig vor große Herausforderungen.

**Interdisziplinäre Teams** und **Domainwissen** sind wichtige Erfolgsfaktoren für eine erfolgreiche Identifikation und Implementierung geeigneter Use Cases.

Bringen Sie Ihre **Geschäfts-, Fach- und Technologieexperten zusammen** und profitieren sie von einem erprobten Prozess zur systematischen Identifikation von Use Cases und der Überführung dieser in die Serienreife.

Erfolgreiche Use Cases führen zur Erhöhung der Akzeptanz für Data Science.



# INHALTSVERZEICHNIS

Kurzfassung	4
Technische Möglichkeiten	5
Methodik des Use-Case Sprints	9
Data Science Use-Case Canvas	12
Praxisbeispiele	16

# KURZFASSUNG

Die Nutzung von Potenzialen durch Data Science ermöglicht Unternehmen häufig einen Wettbewerbsvorteil. Kosten senken, Lagerbestände optimieren, die Produktivität steigern, Umsätze erhöhen, Cashflows maximieren oder Risiken allokkieren – der Einsatz von Data Science-Technologien schafft über verschiedene Bereiche hinweg einen Mehrwert. Darüber hinaus prägt der Einsatz von Methoden der künstlichen Intelligenz unseren Alltag – von intelligenten Assistenten wie Alexa bis hin zu Musikvorschlägen bei Spotify. In vielen Unternehmen zeichnet sich jedoch ein anderes Bild in Bezug auf die Digitalisierung ab: KI und Data Science stecken oft noch in den Kinderschuhen, während gleichzeitig vielfältige Hürden für einen Einsatz von künstlicher Intelligenz im Unternehmen bestehen.

Neben fehlendem Know-how, einem Mangel an Data-Science-Talenten und technischer Infrastruktur sowie unbekanntem Analysetools und -methoden fehlt es an auch an Maßnahmen zur Ableitung von Handlungsempfehlungen für einen strukturierten Use-Case-Prozess, was eine praxisnahe Einführung von Machine Learning Anwendungsfällen erschwert. In den meisten Unternehmen herrscht Unsicherheit über die richtigen Investitionsbereiche und den genauen Mehrwert von Data Science Projekten.

## Unsere Lösung:

TCW hat ein standardisiertes Vorgehen entwickelt, welches Unternehmen bei der systematischen Entwicklung und Bewertung von Use Cases unterstützt und die Grundlage für die Erstellung von Proof-of-Concepts schafft. Im Anschluss folgt die Überführung von potentialträchtigen Anwendungsfällen in die Serienreife. Die systematische Identifikation und Umsetzung konkreter Leuchtturmprojekte ermöglicht Unternehmen Potenziale aus datenverarbeitender Technologie zu erheben und zudem die Akzeptanz für zukünftige Technologieprojekte in der Belegschaft zu steigern. Im Mittelpunkt steht dabei ein erprobter Prozess: Er bezieht sowohl Mitarbeiter mit Domainwissen als auch Geschäfts-, Fach- und Technologieexperten mit ein.

Gestartet wird mit einer Interviewphase, in der die Datenlandschaft und der Reifegrad des Unternehmens bestimmt werden. Gemeinsam mit den Mitarbeitern werden Pain-Points visualisiert und Ideen gesammelt. Anschließend werden die Ideen in interdisziplinären Workshops konkretisiert und priorisiert. Die entwickelten Use Cases werden detailliert und evaluiert. Die systematische Aufbereitung der Use Cases erfolgt mittels eines Data Science Use Case Canvas, der die entscheidenden Aspekte eines jeden Data Science Projekts abdeckt (Workshopphase). Im letzten Schritt erfolgt die Auswahl und Definition geeigneter Pilotprojekte und die Erstellung des Proof-of-Concepts sowie die Erstellung der Umsetzungsroadmap.

## Beispiel:

Bei einem global agierenden Automobilzulieferer mit 3 Geschäftsbereichen wurden mit der TCW-Methodik 28 Use Cases aus den Bereichen Einkauf, Controlling, Produktion und Konzernrevision generiert. In einer weiteren Iteration wurden 11 Use-Cases weiterentwickelt, jeweils ein Proof-of-Concept erstellt und diese zur Serienreife geführt.





# TECHNISCHE MÖGLICHKEITEN

# TECHNISCHE MÖGLICHKEITEN



## Data Science:

Data Science befasst sich mit dem Extrahieren von Informationen aus Daten. Für Unternehmen wird besonders der Bereich Machine Learning interessant, wobei Computerprogramme aus einer Datenbasis lernen und anschließend Aussagen zu Daten bereitstellen können. Technisch lassen sich folgende Gruppen von Problemstellungen aufteilen:

- **Unsupervised Learning**  
Es liegen Daten vor, aus denen etwas Neues gelernt werden soll, d.h. es sollen Zusammenhänge, Ähnlichkeiten, Einflussstrukturen etc. abgeleitet werden.
- **Supervised Learning**  
Daten sind vorhanden und man möchte einen menschlichen Entscheidungsprozess automatisieren, d.h. z.B. anhand eines Musters vorhandener Daten eine Vorhersage treffen oder eine Klassifizierung vornehmen.
- **Verstärkendes Lernen:**  
Jede einzelne Entscheidung eines fortgeschrittenen maschinellen Lernmodells wird überprüft und die Erkenntnisse genutzt, um das Lernmodell zu optimieren. Diese Modelle werden z.B. für autonome Fahrsysteme eingesetzt und spielen daher für die gängige Anwendungen der meisten Unternehmen eine untergeordnete Rolle.

Das **überwachte Lernen („supervised learning“)** sucht nach Zusammenhängen in Daten und versucht dann, eine Variable durch andere zu modellieren. Das Ergebnis ist eine Schätzfunktion, in die einzelne Datensätze eingegeben werden können, um einen Ergebniswert für einen bestimmten Datensatz zu erhalten. Das Ziel kann darin bestehen, einen zeitlichen Informationsvorsprung zu erhalten oder die menschliche Bearbeitung zu automatisieren.

**Lineare Regression:** Ein freier Ergebniswert wird aus den Daten vorhergesagt. Dazu werden die einflussreichsten unabhängigen Variablen in eine Funktion eingesetzt, um die abhängige Zielvariable zu modellieren. Im einfachsten Fall kann man sich eine lineare Funktion vorstellen, die bei einem eingegebenen X-Wert einen Y-Wert ausgibt. Beispielsweise könnte aus Werten wie Bestellungen, Retouren und Vorjahreswerten der zukünftige Warenabsatz prognostiziert werden.

**Klassifikationen:** Wie bei der Regression wird eine Schätzfunktion verwendet, um ein Ergebnis aus Daten vorherzusagen. Dieses Ergebnis ist jedoch kein tatsächlicher Wert, sondern eine Klassenzugehörigkeit. Ein Beispiel ist ein Modell, das nach Eingabe einiger Eingabeparameter entscheiden kann, ob es sich bei einer E-Mail um Spam handelt oder nicht.

Die Unterscheidung zum unüberwachten Lernen: Die Bezeichnung „überwachtes Lernen“ entstammt der Tatsache, dass die Zielvariablen zum Trainieren des Modells bereits bekannt sind. Diese Zielwerte dienen als Überwachung der Funktionsweise des Modells, da sie zu jeder Vorhersage einen korrekten Vergleichswert bieten.

Das **unüberwachte Lernen („Unsupervised Learning“)** zielt darauf ab, Muster in vorhandenen Daten zu ermitteln. Da Datenmengen mit zunehmender Anzahl an Dimensionen nicht mehr übersichtlich dargestellt werden, können Zusammenhänge hierdurch erkennbar gestaltet werden. Im Gegensatz zum überwachten Lernen gibt es keine Zielvariable, die die Qualität der Ergebnisse „überwacht“. Der Anwender muss die Ergebnisse selbst unter Einbezug von Domänenwissen bewerten.

**Segmentierung:** Die Datensätze werden auf Ähnlichkeiten in den Variablenwerten untersucht und zu Clustern zusammengefasst. Es gibt verschiedene Verfahren zur Clusterbildung mit einer vorab (unterschiedlich) festgelegten Anzahl an Clustern. Ein Unternehmen kann seine Bestandskunden nach verschiedenen Merkmalsausprägungen bewerten und innerhalb dieser Cluster bilden. So kann beispielsweise analysiert werden, ob und in welchen Clustern bestimmte Aktionen bei bestimmten Kundensegmenten besser greifen. Ebenfalls ermöglichen diese Verfahren eine Anomalieerkennung, bei der Datenpunkte herausgestellt werden, die keinem Cluster bzw. den Gesamtdaten zugeordnet werden können.

**Assoziationsanalyse:** Zwischen einzelnen Datenpunkten wird nach bestimmten Ähnlichkeitskriterien mit dem vorrangigen Ziel gesucht, Rückschlüsse auf Mechanismen zu ziehen, die den in den Daten sichtbaren Trends zugrunde liegen. Zum Beispiel können Supermärkte in Transaktionslisten nach Artikeln suchen, die gemeinsam gekauft werden. Daraus können verschiedene Theorien zu Konsumententscheidungen abgeleitet werden, bspw. dass ein Kunde, der Mehl und Butter kauft, zu 70% auch Zucker mit einkauft. Auf der Grundlage dieser Datenerkenntnisse können dann Marketingentscheidungen getroffen oder das Kundenerlebnis durch eine Neuordnung der Waren verbessert werden.

Im Rahmen der Assoziationsanalyse werden mehrere **Data Science Anwendungen** vorgenommen:

In Simulationen werden reale Phänomene so modelliert, dass Vorhersagen über Zukunftsszenarien getroffen werden können. Process Mining ist die virtuelle Nachbildung von Prozessen mit realen Daten, um z.B. Engpässe aufzudecken. Über Tests mit dem Prozessmodell kann so die effizienteste Konfiguration bestimmt werden, ohne den realen Prozessablauf zu stören. Robotic Process Automation (RPA) ist die Automatisierung wiederkehrender Arbeitsabläufen über verschiedene Softwareprogramme hinweg. Durch kleine Code-Skripte können Datenexporte und -importe in standardisierbarer Verarbeitung definiert und manuelle Arbeit somit eingespart werden.

Die Verbindung aus der Verarbeitung natürlicher Sprache (Natural Language Processing – NLP) mit Machine Learning stellt ein zukunftsweisendes Tool dar, um Dokumente zu interpretieren und/oder in Mustern zu kommunizieren. Realisiert werden können damit vielerlei inhaltliche Klassifizierungen z.B. von Rechnungen, Verträgen bis hin zu Chat-Bots als erste Anlaufstelle im Geschäfts- und Kundenkontakt.

### **Schlussfolgerung für Unternehmen:**

Aus strategischer Sicht können Unternehmen aller Branchen jetzt einen erheblichen Geschäftswert aus Daten generieren und sich gleichzeitig einen entscheidenden und dauerhaften Wettbewerbsvorteil für die Zukunft verschaffen. **Start with first pilots!** TCW unterstützt Sie dabei, eine Auswahl von Anwendungsfällen, die das Potenzial haben, zu sichtbaren Leuchtturmfällen zu werden, zu finden und umzusetzen. Erste messbare Ergebnisse führen häufig dazu, „Data, Analytics & AI“ anschließend nachhaltig im Unternehmen zu verankern.

# ANSÄTZE DES MACHINE LEARNINGS





# METHODIK DES USE-CASE SPRINTS

# METHODIK DES USE-CASE SPRINTS

## 1. Interviewphase



## 2. Workshopphase



## 3. Pilotprojekt



### Identifikation und erste Bewertung von Use Case Ideen

- Durchführung von Interviews mit Teilnehmern aus verschiedenen Unternehmensbereichen
- Identifikation von Pain-Points und Use Case Ideen
- Erste Priorisierung und Bewertung der Ideen sowie Schwerpunkt-Festlegung der Workshopphase

### Konkretisierung und Priorisierung von Use Cases

- Durchführung interdisziplinärer Workshops in den Fachbereichen
- Konkretisierung identifizierter Use Case Ideen
- Detaillierung von Datenquellen, Mehrwert und Rahmenbedingungen der Use Cases

### Projektplanung und Pitch von Leuchtturm-Pilotprojekten

- Gemeinsame Priorisierung der Use Cases
- Auswahl und Definition geeigneter Pilotprojekte
- Ausarbeitung einer Umsetzungsunterstützung
- Start!

## Methodik des Use Case Sprints:

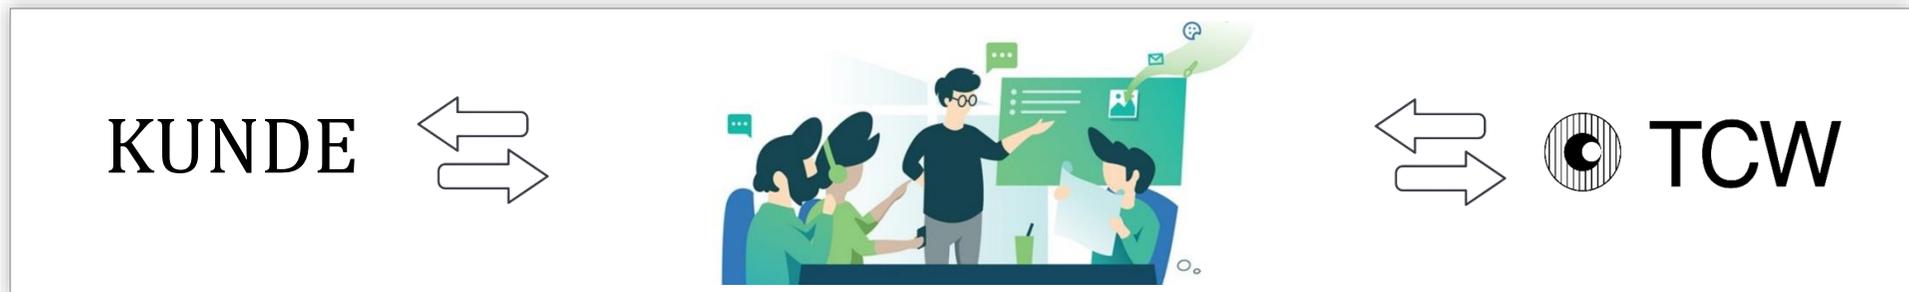
Der Use Case Sprint ist eine Methode zur Konkretisierung identifizierter Use Cases aus dem vorausgehenden Identifikationsschritt. Hierbei werden mögliche Use Cases (Anwendungsfälle) ausgewählt und in einem intensiven, iterativen Prozess weiterentwickelt und validiert. Entwickler, Designer und Stakeholder arbeiten eng zusammen, um die Anforderungen aller Endbenutzer aufzufassen, zu priorisieren, quantitativ und qualitativ zu bewerten und Success Stories abzuleiten. Nachfolgend werden die Abläufe der Interviewphase, der Workshopphase sowie der zugrunde liegenden Methodik beschrieben:

**Interviewphase:** Die Interviewphase dient der Abfrage und Einordnung spezifischen Domainwissens zur Use Case Erstellung. Dabei werden zuerst die Einflussbereiche eingegrenzt, beispielsweise Produktion und Logistik. Anschließend werden Ideen mit bereits bestehenden Use Cases abgeglichen und einbezogene Systeme, Zusammenhänge und erforderliche Daten in einer ersten KI-Lab Analyse eingeschätzt. Aus diesen Informationen wird ein Business Case vorformuliert, welcher dem Management präsentiert wird.

**Workshopphase:** In der anschließenden Workshopphase werden Seminare mit Design Thinking und Canvas Ansätzen in interdisziplinären Teams durchgeführt. Das Ziel hierbei besteht darin, eine detaillierte Problembeschreibung auszuformulieren. Dazu wird ein Use Case Canvas ausgefüllt und ein Business Case mit zugeordneten KPIs zur Erfolgskontrolle als Rahmen aufgesetzt. Letztlich werden in der Workshopphase Mockups und eine Checkliste für alle Ansprechpartner erstellt, die beispielsweise der Sicherstellung der Daten- und Ergebnisqualität dient.

## Die Methodik eines Use Case Sprints besteht aus folgenden Schritten:

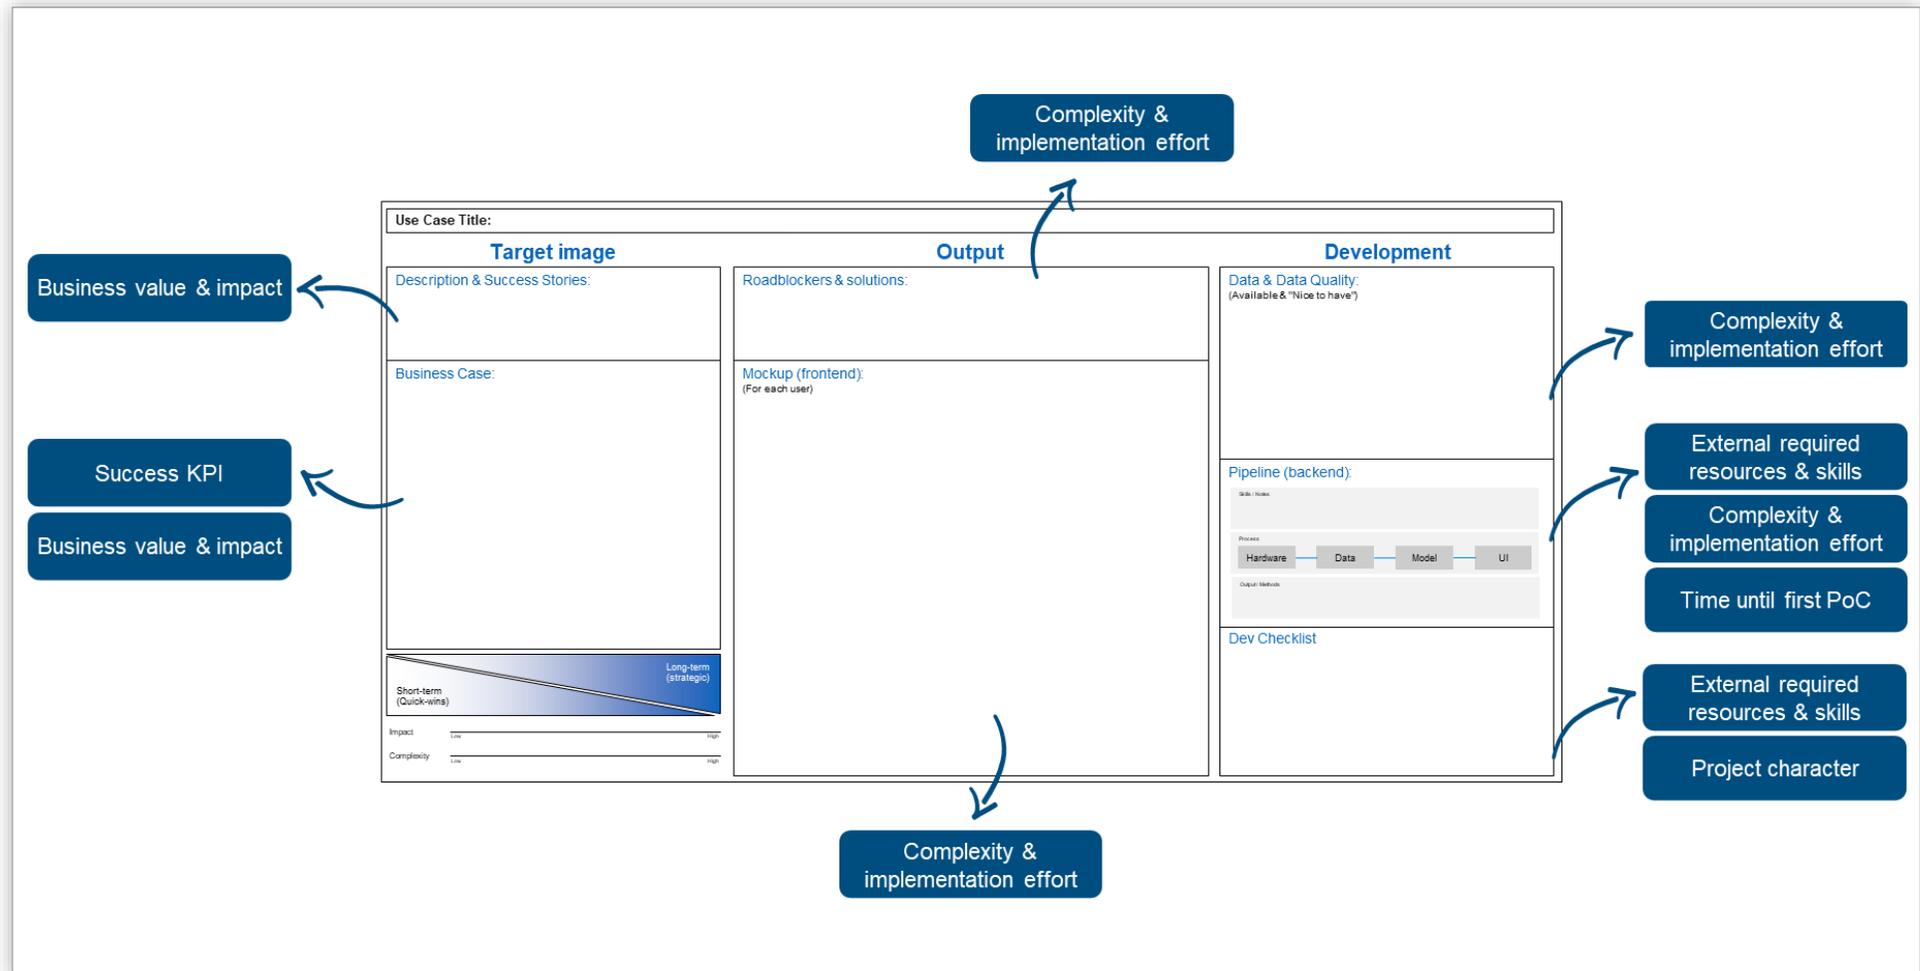
Das Team beginnt mit der Definition des zu lösenden Problems, bei der Pain-Points und Roadblocker berücksichtigt werden. Dann findet eine Ideengenerierung statt, bei der mögliche Lösungen und Use Cases gesammelt werden. Anschließend werden die passendsten Use Cases ausgewählt und priorisiert. Das Team entwickelt erste Konzepte für ausgewählte Use Cases und stellt sicher, dass sie den Anforderungen der Endbenutzer entsprechen. Diese Konzepte werden bei echten Benutzern validiert und das Feedback wird zur Weiterentwicklung einbezogen. Sobald ein Konzept validiert wurde, geht es in die Umsetzung. Dieser Prozess wird wiederholt, bis alle wichtigen Use Cases entwickelt, ausformuliert und umgesetzt wurden.





# DATA SCIENCE USE-CASE CANVAS

# DATA SCIENCE USE-CASE CANVAS



**Warum?** Der Use Case Canvas dient als strategisches Toolkit zur Visualisierung und Bewertung von Use-Cases.



## Data Science Use-Case Canvas

Ein Use-Case Canvas ist in mehrere Felder unterteilt und übergeordnet in drei Hauptblöcken angeordnet. Er muss nicht in strikter Reihenfolge ausgefüllt werden, die generelle Lese- und Bearbeitungsrichtung ist jedoch von links nach rechts. Der linke Block Kundensituation dient der Problembeschreibung des Use Cases mit Informationen zu Aufgaben und Gewinnen. Der mittlere Block Lösungsansatz beschreibt den Use Case, Datentypen, Fähigkeiten sowie anfallende Kosten. Letztlich dient der rechte Block Ergebnisse der Erfassung der Stakeholder, Value Proposition, dem Output inkl. Integration sowie dem Potenzial.

**Kundensituation:** Am Beginn der Canvas-Erstellung für einen Use Case steht die Problembeschreibung in der Kundensituation. Der Begriff Kunde bezieht sich hier nicht etwa auf einen Kunden des Unternehmens, sondern soll als das Zielobjekt verstanden werden, welches vom Outcome des Use Cases profitiert – bspw. ein Stellvertretender Mitarbeiter im Unternehmen, dessen Arbeitstätigkeiten durch erarbeitete Lösungen optimiert werden können. Die Unterpunkte Personal, Schmerzen, Aufgaben und Gewinne enthält dazu entsprechend eine Personen-beschreibung, Problemheranführung und Optimierungsmaßnahmen für konkrete Aufgaben.

**Use Case:** Der zweite Hauptblock definiert diesen Lösungsansatz: Der erste Unterpunkt formuliert diesen konzise, Daten beschreibt benötigte Daten, die Ursprungsquellen sowie die Speicherung und die dafür notwendige Infrastruktur. Fähigkeiten & Technologien sollen möglichst genau beschreiben, wie das Data Science Projekt technisch umgesetzt wird. Welche Modellierung wird gebraucht? In welcher Programmiersprache wird es realisiert? Welche Programme werden genutzt? Und, welche Teamrollen sind für das Projekt notwendig? Im zweiten Unterpunkt Fähigkeiten & Technologien erfolgt eine Beschreibung der technischen Umsetzung des Data Science Projekts. Hier wird definiert in welcher Programmiersprache in welchen Programmen eine Umsetzung erfolgt. Weiterhin werden die Teamrollen für das Projekt definiert. Abgeleitet daraus kann der Kostenrahmen für das Projekt eingeschätzt werden.

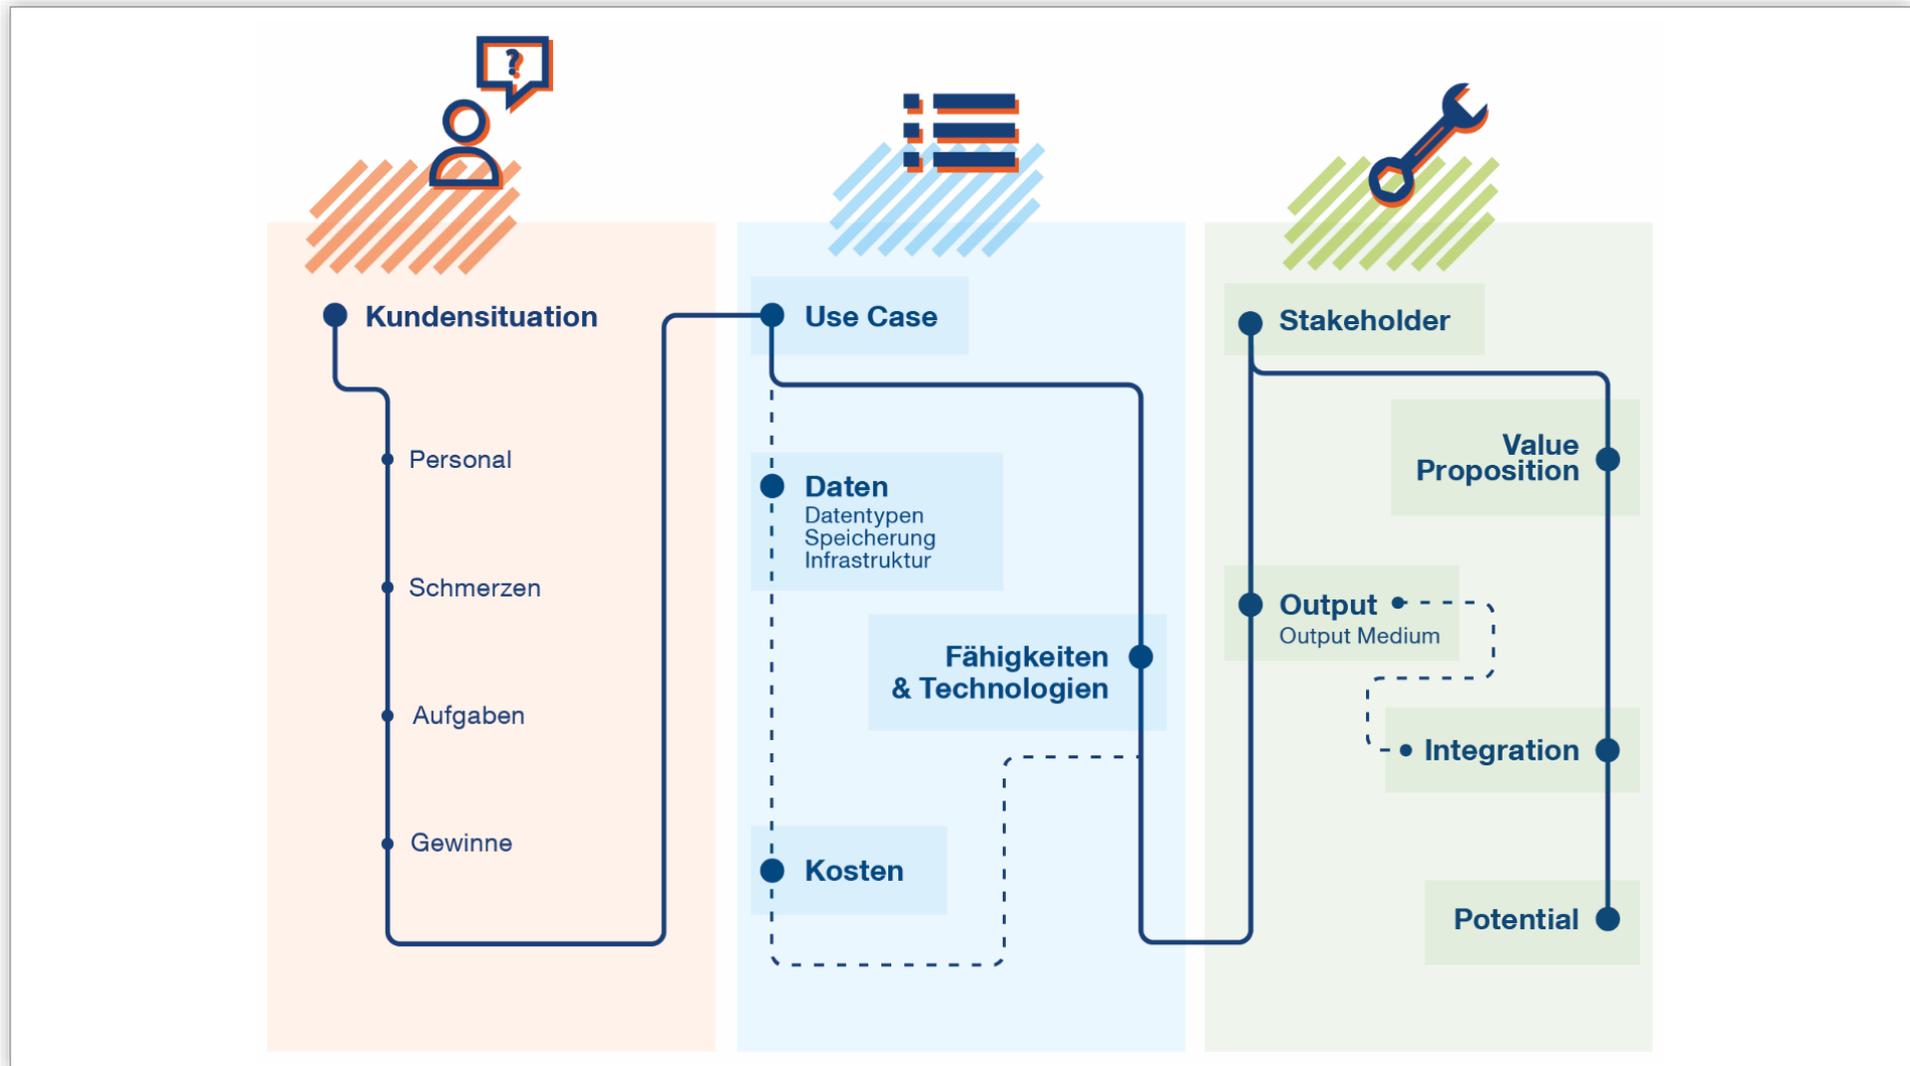
Kosten sind hierbei nicht zwangsläufig als Geldbetrag definiert, sondern können auch in Zeit- bzw. Personenaufwand bemessen werden, was vor allem in frühen Projektphasen eine grundsätzliche Einschätzung ermöglicht. Ziel ist eine Quantifizierung des Aufwandes für den Anwendungsfall.

**Stakeholder:** Im dritten Hauptblock werden Lösungsergebnisse präsentiert. Der Unterpunkt Stakeholder listet alle beeinflussten- und integrierten Parteien auf, die direkt oder indirekt von den Ergebnissen des Canvas profitieren bzw. eine Beziehung zum Projekt haben. Dies ermöglicht, Kooperationen, nächste Schritte und weitere Anwendungsmöglichkeiten im angrenzenden Use-Case-Umfeld zu identifizieren. Ein zielgerichtetes Wertversprechen wird dazu im Unterpunkt Value Proposition herausgearbeitet, die technische Umsetzung mit verwendeten Output Medien dazu im Punkt Output erläutert. Dieser Unterpunkt kann je nach Projekt aus einem kurzen .pdf-Bericht bis hin zu interaktiv aufgebauten Datenbanken inklusive Toolanbidungen bestehen. Die Integration unterstreicht hierbei eine Einbettung in bestehende (IT-)Prozesse des Unternehmens. Als letzten Unterpunkt werden im Potenzial als Pendant zur Kosteneinschätzung die langfristigen Ergebnischeckpoints des Projektes dargestellt. Mithilfe des Canvas-Modells kann ein Data Science Use Case ganzheitlich erfasst werden. Die klare Strukturierung ermöglicht dabei eine vereinfachte Herangehensweise in der Erarbeitung des Projektablaufes, dient als Diskussionsgrundlage zur Präsentation sowie zum Check von Ergebniskontrollpunkten.

### Schlussfolgerung für Unternehmen:

Ein Data Use-Case Canvas ist ein Werkzeug, welches Unternehmen dabei hilft, Datenanforderungen und -nutzungen für einen bestimmten Geschäftsanwendungsfall zu definieren und zu visualisieren. Er dient dazu, die Vorgehensweisen des Unternehmens zu strukturieren und dabei sowohl die Datennutzung als auch die Value Proposition effizienter zu gestalten.

# ANWENDUNG DES USE-CASE CANVAS



# PRAXISBEISPIELE

# Praxisbeispiele



**Möhlenhoff**

Im Projekt wurde die Wichtigkeit von Single-Source of Truth herausgestellt, weiterhin konnten durch die Workshops Synergien an den Schnittstellen erzielt werden. In der Interviewphase wurden 30 Use-Case Ideen aus verschiedenen Fachbereichen bewertet, aus welchen 7 Proof of Concepts erstellt wurden.

---



Die Ideenfiltration erfolgte durch Scoping Interviews, Reifegradanalysen und Pain-Point Identifikation. Aus den ersten Gesprächen resultierten 27 Use-Case Ideen, aus welchen 4 Proof of Concepts erstellt wurden.

---

**iwis**

wir bewegen die welt

In der Zusammenarbeit konnten Potenziale und Synergien in allen festgelegten Themenbereichen erzielt werden. Aus den ersten Gesprächen resultierten 28 Use-Case Ideen, von denen im Projektverlauf 11 antizipierte Use-Cases zur Konkretisierung ausgewählt wurden.

# Use-Case Vorstellung

## Optimierung eines Fertigungsleitstandes



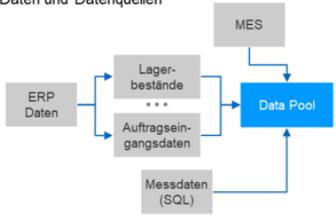
### Ergebnisse

- » Fokussierung auf Kernbereiche in der Ideengenerierung ermöglichte Anpacken der Themen in einer drei Tage Woche für die Workshops,
- » Kernpunkte: „Mehr Daten in der Produktion“, „Transparenz und Dashboards in Vertrieb“



### KPIs im Anwendungsbereich

- » Qualitätssicherung durch Einkaufs-Dashboards und Optimierung von Kalkulationstools

Use Case Titel: Fertigungsleitstand	
Zielbild	Output
<p><b>Problem</b></p> <ul style="list-style-type: none"> <li>Schlechte Informationsqualität</li> <li>Zeitlicher Versatz / Keine Echtzeitdaten</li> <li>Unzureichende Ursachenanalysen</li> </ul> <p><b>Beschreibung</b></p> <ul style="list-style-type: none"> <li>Detaillierte Soll-/Ist-Analysen -&gt; Trends / Früherkennung</li> <li>Echtzeitdaten</li> <li>Ursachen-/Wirkungszusammenhänge</li> <li>ERP / MES Schnittstelle</li> </ul> <p><b>Mehrwert / Business Case</b></p> <ul style="list-style-type: none"> <li>Produktivität -&gt; Stillstände ↓, Output ↑</li> <li>Planungssicherheit &amp; - validität</li> <li>Vermeidung von Mehrarbeit</li> <li>Maschinenauslastung ↑</li> </ul> <p><b>Stakeholder</b></p> <ul style="list-style-type: none"> <li>Produktion (Teamleiter, Maschinenfürer) (Kernnutzer)</li> <li>Unternehmensweit (Reports)</li> </ul>	<p><b>Beispielanwendungen / User Stories</b></p> <ul style="list-style-type: none"> <li>„Ich (Instandhaltung) möchte wissen, wo der Fehler ist und wie ich ihn behebe.“</li> <li>„Ich (Produktionsplanung) möchte eine Echtzeitübersicht über die Ressourcen.“</li> <li>„Ich (Fertigung) möchte ein automatisiertes Reporting.“</li> <li>„Ich (Fertigung) möchte zeitnah auf Störgrößen reagieren können.“</li> </ul> <p><b>Visualisierung, Ergebnisse und KPIs</b></p> <ul style="list-style-type: none"> <li>Produktionsvolumen</li> <li>Mitarbeiter &amp; Kapazitätsplanung</li> <li>Ausschuss</li> <li>Materialverfügbarkeit</li> <li>Fehleranalysen (je Station, je Schicht, je Fehlerart, je Uhrzeit, ...)</li> </ul> 
	Entwicklung
	<p><b>Erfolgs-KPI</b>      <b>Produktivität</b></p> <p><b>Daten und Datenquellen</b></p>  <p><b>Methode und Technologien</b></p> <ul style="list-style-type: none"> <li>Historische Daten</li> <li>Livedaten</li> <li>Datenkonsolidierung (Knime, Alteryx)</li> <li>Visualisierung</li> <li>Proaktive Empfehlungen</li> </ul>

# Use-Case Vorstellung

## Einführung eines Supplier-Scores

**Use Case Title: Supplier score**

**Target image**

**Description & Success Stories:**

**Description:** There is a lack of transparency regarding supplier quality and a general lack of communication between functional areas. This can be addressed by a systemized supplier rating approach and corresponding tool.

**Success Story:** Supply chain resilience will be increased. Delivery capability will be ensured.

**Success Story:** Multi-sourcing potential for critical suppliers with high dependencies will be identified.

**Success Story:** Downtime, malfunctions and complains will be reduced and fast decision making will be ensured.

**Success Story:** Communication between purchasing and production will be improved.

**Business Case:**

**Beer Coaster Business Case**

Summary: [Graph showing metrics]

Quantitative: [Table with metrics]

Qualitative: [Table with metrics]

Short-term (Quick-wins) vs Long-term (strategie) graph

Impact vs Complexity graph

**Supplier resilience score**

- Supply chain resilience through comprehensive supplier assessment beyond product costs
- Multi-sourcing potential for critical suppliers with high dependencies

**Output**

**Roadblockers & solutions:**

**Roadblocker:** Conflicting goals between functional areas. **Solution approach:** Cooperative definition of goals with CEO as lead.

**Roadblocker:** Allocation of costs and mistakes to suppliers is difficult. **Solution approach:** Systematic tracking or process adaptation could be implemented.

**Mockup (frontend):** (For each user)

**Development**

**Data & Data Quality:** (Available & "Nice to have")

SAP → Lead-time, Should / is, Complaint time → Supplier portal (purchasing)

External data → Babtec CAQ → Supplier Scorecard, complains

**Pipeline (backend):**

Success measures, Generalizability

Process: ~~Hardware~~ → Data → Model → UI

Output / Methods: Augmentation of quality and productivity KPIs, Descriptive analysis, KPI visualization, Criticality and risk alerts

**Dev Checklist:**

User → Solution: Purchasing, supplier development, management

Type of analysis: Visualisation, qualitative descriptive analysis

Skills: ---

Hardware: No specific hardware requirements

Connection: Offline

Preliminary work: Supplier development division

Product specificity: ---

Division specificity: Scalable over different BUS

Focus: ---

Team: Production, purchasing, QA, logistics, mgmt., supplier developm.



### Ergebnisse

- » Widerstandsfähigkeit der Lieferkette wurde erhöht
- » Ausfallzeiten, Fehlfunktionen und Reklamationen wurden reduziert
- » Verbesserte Kommunikation zwischen Einkauf und Produktion



### KPIs im Anwendungsbereich

- » Qualitäts- & Produktivitätskennzahlen

# Use-Case Vorstellung

## Optimierung von Patentanmeldungen



### Ergebnisse

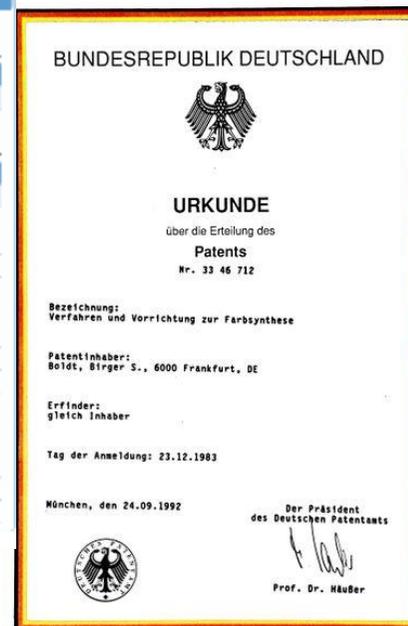
- » Erhöhung der Anzahl an angemeldeten Patenten
- » Verringerte Dauer der Erfindungsbewertung
- » Verbesserung der Kommunikation zwischen Recht und Entwicklung



### KPIs im Anwendungsbereich

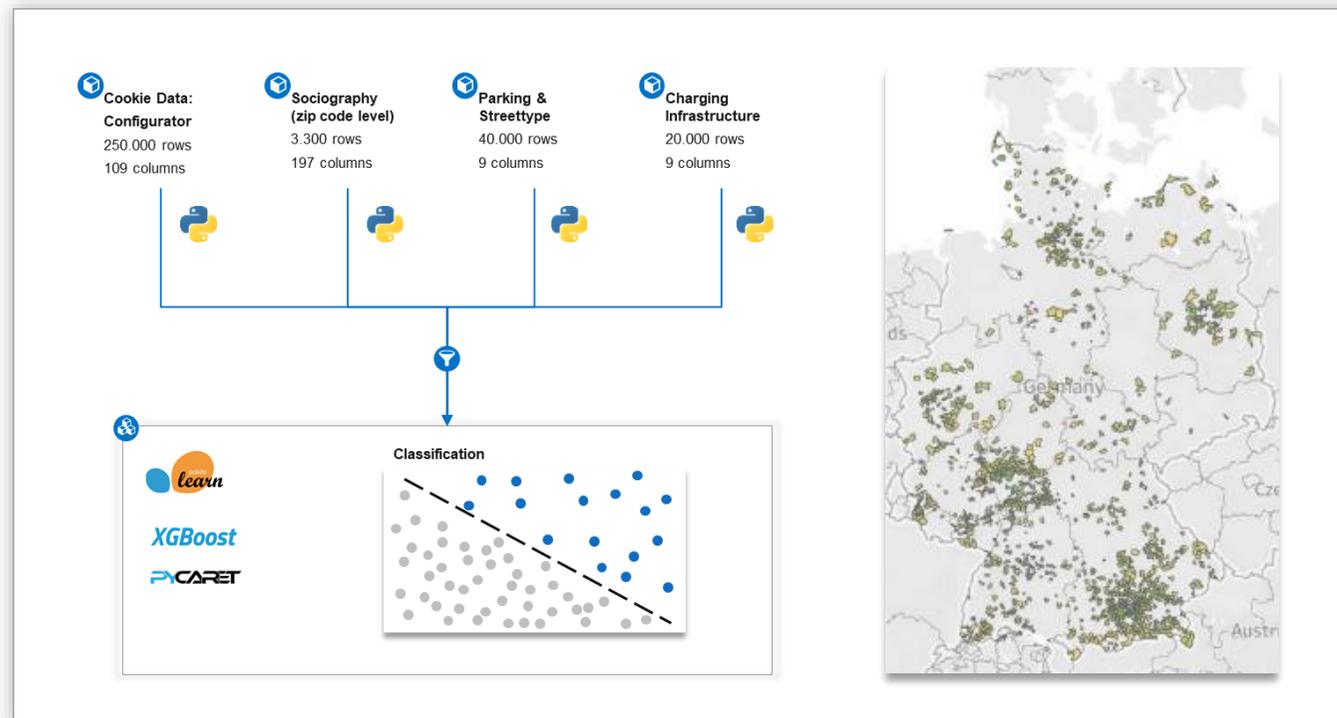
- » Anzahl gewährter Patente
- » Anzahl Patentverletzungen

Patentanmeldungen		Patentanmeldungen	
Legaldaily	Description	Download	
18.01.2010	Copy of the international search report	PDF (2MB) (1 page)	
18.01.2010	International publication of the invention	PDF (2MB) (21 pages)	
18.02.2010	Priority document (deposited copy)	PDF (1MB) (28 pages)	
23.11.2010	Information on the Info Database of the	PDF (2MB) (4 pages)	
20.11.2010	[Electron] Receipt	PDF (2MB) (1 page)	
20.11.2010	Registration and status of the patent	PDF (2MB) (1 page)	
17.07.2011	Copy of the international preliminary examination report	PDF (2MB) (1 page)	
15.02.2019	Communication to designated inventor	PDF (2MB) (1 page)	
15.02.2019	Communication to designated inventor	PDF (2MB) (1 page)	
16.03.2019	Communication regarding possible amendment of the application payment of claims fee	PDF (2MB) (1 page)	
05.03.2019	Amendment has not been notified	PDF (2MB) (1 page)	
16.03.2019	Communication regarding amendment of claims	PDF (2MB) (1 page)	
17.04.2019	Notification of the communication of the international data	PDF (2MB) (1 page)	



# Use-Case Vorstellung

## Lead-Prediction auf Basis von Cookie-Daten



### Ergebnisse

- » Vorhersage, ob ein Website-Besucher zum potenziellen Kunde (Lead) wird
- » Senkung der Kosten für die Kundenbindung, Erhöhung der Gewinnmarge, Effektiver Einsatz des Marketingbudgets



### KPIs im Anwendungsbereich

- » Click-Through Rate, Conversion Rate, Targeting von Anzeigen, Marketingkosten



Data Science als Wettbewerbsvorteil  
Use Case Sprint – Das systematische Vorgehen zur Identifizierung  
und Umsetzung von Data Science Use Cases & Potenzialen

Whitepaper

1. Auflage, München 2023