

Herzlich Willkommen zur Online Session –  
gleich geht es los

# Von der Idee zum Datenprodukt

Wie Sie Ihre Data-Science-Projekte zum Erfolg machen?



Experte

**Martin Schneider**

Chief Data Scientist



# Organisatorische Hinweise



Wir freuen uns auf Ihre Fragen im Chat –  
unser Experte geht sehr gerne im  
Nachgang an die Präsentation darauf ein



Die Präsentationsfolien stellen wir Ihnen  
im Anschluss zur Verfügung

Online Session

## Von der Idee zum Datenprodukt

Was ist ein Datenprodukt?

Wie definiere ich Use Cases richtig?

Wie sieht das Setup erfolgreicher Data-Science-Projekte aus?

Wieso ist Kollaboration ein so wichtiger Erfolgsfaktor?

Wie gelingt die Überführung in das Daily Business?

### FRAGEN & ANTWORTEN

Wir freuen uns auf Ihre Fragen im Chat.





„Unternehmen verfügen über große Datenmengen.

Wieso nutzen sie das darin enthaltene Wissen nicht besser?“

—

Oliver Bracht | 2010

Mitgründer & CEO



**INFRASTRUKTUR**

**LÖSUNGEN**

**STRATEGIE**

**DATA SCIENCE & KI**

Mit uns von der Vision bis zum Produktiveinsatz

> 50 Mitarbeitende, > 400 Kunden – eine Mission:  
Aus Daten Mehrwerte generieren



B | BRAUN



Online Session

## Von der Idee zum Datenprodukt

Was ist ein Datenprodukt?

Wie definiere ich Use Cases richtig?

Wie sieht das Setup erfolgreicher Data-Science-Projekte aus?

Wieso ist Kollaboration ein so wichtiger Erfolgsfaktor?

Wie gelingt die Überführung in das Daily Business?

### FRAGEN & ANTWORTEN

Wir freuen uns auf Ihre Fragen im Chat.




# Was ist ein *Datenprodukt*?

Ein **Datenprodukt** ist ein aufbereiteter, hochwertiger Datensatz oder Service, der wie ein eigenständiges Produkt behandelt wird, um spezifische geschäftliche Probleme zu lösen.

Es verwandelt Rohdaten in vertrauenswürdige, nutzbare Erkenntnisse, ist auffindbar, dokumentiert und wird kontinuierlich gewartet.

# Wie können Datenprodukte aussehen?



Vorhersagemodell  
über API



KPI-Dashboard



Aufbereiteter  
Datensatz

Beispiele für Datenprodukte | Vorhersagemodell

## Präzise Prognose des Netzverlusts

Verlässliche Vorhersage der Stromverluste während des Transports zur Planung der benötigten Kompensation



Beispiele für Datenprodukte | KPI-Dashboard

## Applikationen für die bessere Einbindung von Daten und Analysen im Klinikalltag

Wie ist die Auslastung von OP-Sälen und Laboren?  
Welche Art von Eingriffen werden wie oft durchgeführt?  
Das KPI-Dashboard gibt schnelle und belastbare  
Antworten

D | Z C

DEUTSCHES HERZZENTRUM  
DER CHARITÉ



Beispiele für Datenprodukte | Aufbereiteter Datensatz

## Zusammenführung und Aufbereitung von CRM-Daten nach Unternehmensfusion

Erschließung der Kundendaten als wichtiges Asset für die Optimierung aller kundennahen Prozesse



# Herausforderung Produktiveinsatz

**Why 90 percent of all machine learning models never make it into production**

**87% of ML Projects Fail**

**88% of AI pilots fail to reach production**

Quellen:


<https://www.cio.com/article/3850763/88-of-ai-pilots-fail-to-reach-production-but-thats-not-all-on-it.html>

<https://medium.com/data-science/why-90-percent-of-all-machine-learning-models-never-make-it-into-production-ce7e250d5a4a>

<https://sbinfowaves.com/why-87-of-ml-projects-fail-and-how-ai-ml-development-services-can-help/>

# Warum scheitern viele Data-Science-Initiativen auf dem Weg der Produktivsetzung?

- Use Cases sind nicht gut definiert – kein klarer Business-Zweck
- Fehlende Zusammenarbeit und Silodenken
- Fehlende Verantwortlichkeiten
- Keine Nutzerintegration
- Unzureichende Datenbasis
- Proof-of-Concept bleibt stecken (keine Deployment-Strategie)



Online Session

## Von der Idee zum Datenprodukt

Was ist ein Datenprodukt?

Wie definiere ich Use Cases richtig?

Wie sieht das Setup erfolgreicher Data-Science-Projekte aus?

Wieso ist Kollaboration ein so wichtiger Erfolgsfaktor?

Wie gelingt die Überführung in das Daily Business?

### FRAGEN & ANTWORTEN

Wir freuen uns auf Ihre Fragen im Chat.



# Den Use Case richtig definieren

## Was gilt es zu prüfen?

- Geschäftswert
- Datenverfügbarkeit
- Technische Machbarkeit



# Den Use Case richtig definieren

## Was sind die häufigsten Fehler?

- Zu komplexer Use Case
- Zu vage Formulierung des Use Cases
- Fehlender Business Owner



# Den Use Case richtig definieren

## Welche KPIs gilt es zu berücksichtigen?

- Technische Metriken (Modellgüte)
  - Accuracy
  - Root Mean Squared Error
  - ...
- Business Metriken (tatsächlicher Impact)
  - Eingesparte Arbeitszeit
  - Umsatzsteigerung
  - ...



# Beispiel für einen *schlechten* Use Case

## KI für bessere Kundeneinblicke

### Ziel & Scope

- Nutzung von Daten und KI, um Kunden besser zu verstehen
- Soll irgendwie ins CRM integriert werden
- Alle verfügbaren Kundendaten sollen einfließen
- Könnte auch für Marketing, Vertrieb und Support nützlich sein

### Rollen & Verantwortlichkeiten

- „Das Team kümmert sich darum“ – kein dedizierter Business Owner benannt
- Data Scientist soll selbst herausfinden, was gebraucht wird
- IT wird „irgendwann eingebunden, wenn es konkreter wird“
- Wer das Ergebnis am Ende nutzt: offen

### Erfolgskriterien & KPIs

- Das Modell soll „möglichst gut“ sein
- Die Ergebnisse sollen „actionable“ und „relevant“ wirken
- Erfolg wird nach Projektabschluss gemeinsam bewertet
- Ein PoC gilt als erfolgreich, wenn das Management „ein gutes Gefühl hat“

### Meilensteine

- „Erstmal schauen, was die Daten hergeben“
- Kein definierter Review-Punkt, kein Go/No-Go-Kriterium
- Zeitplan: „So schnell wie möglich, aber es soll auch gut werden“
- Livegang: „Wenn wir bereit sind“

# Beispiel für einen *guten* Use Case

## Churn-Prediction für B2B-Kunden

### Ziel & Scope

- Vorhersage der Kündigungswahrscheinlichkeit für B2B-Bestandskunden im Segment KMU (< 250 MA)
- Betrachtungszeitraum: Kündigungsrisiko der nächsten 90 Tage
- Eingangsdaten: Vertragshistorie, Support-Ticket-Frequenz, Login-Aktivität, Zahlungsverhalten
- Explizit ausgeschlossen: Neukunden (< 6 Monate Vertragslaufzeit), Konzernkunden mit Key-Account-Betreuung

### Rollen & Verantwortlichkeiten

- Business Owner: Head of Customer Success (entscheidet über Priorisierung & Abnahme)
- Data Scientist: Modellentwicklung & Monitoring
- IT: Anbindung CRM-System & Deployment
- Endnutzer: Customer-Success-Manager (erhalten wöchentlichen Risiko-Report im CRM)

### Erfolgskriterien & KPIs

- Technisch: Precision  $\geq 75\%$  bei Recall  $\geq 60\%$  auf Holdout-Testdaten
- Business: Reduktion der Churn-Rate im KMU-Segment um 10 % innerhalb von 6 Monaten nach Go-live
- Adoption: Mind. 80 % der CSM nutzen den Report aktiv (gemessen via CRM-Klickdaten)
- PoC-Exit-Kriterium: Modell schlägt bestehende Regellogik (Bauchgefühl-Score) auf historischen Daten um mind. 20 %

### Meilensteine

- Woche 1–2: Datenverfügbarkeit prüfen & Feature Engineering
- Woche 3–5: Modellentwicklung & interne Validierung
- Woche 6: PoC-Review mit Business Owner → Go/No-Go-Entscheidung
- Woche 10: Pilotbetrieb mit 2 CSM-Teams
- Woche 16: Rollout & Übergabe in Regelbetrieb

Online Session

## Von der Idee zum Datenprodukt

Was ist ein Datenprodukt?

Wie definiere ich Use Cases richtig?

Wie sieht das Setup erfolgreicher Data-  
Science-Projekte aus?

Wieso ist Kollaboration ein so wichtiger Erfolgsfaktor?

Wie gelingt die Überführung in das Daily Business?

### FRAGEN & ANTWORTEN

Wir freuen uns auf Ihre Fragen im Chat.



# Das Setup erfolgreicher Data-Science-Projekte: Projektrollen

Projektleitung

Data Engineer

Data Scientist

Business Owner



# Das Setup erfolgreicher Data-Science-Projekte:

## Projektmeilensteine

### PROJEKTPHASE

### ERREICHTER MEILENSTEIN

Rollout

Das Datenprodukt ist in vollem Funktionsumfang produktiv nutzbar

Pilotprojekt / MvP

Es besteht eine produktiv nutzbare Lösung mit geringem Funktionsumfang

Proof-of-Concept

Machbarkeit ist mithilfe konkreter KPIs bewiesen

Exploration / Discovery

- Use Case ist definiert
- Voraussetzungen wurden überprüft (z.B. Infrastruktur und Daten)
- Es gibt eine definierte Umsetzungsstrategie

# Das Setup erfolgreicher Data-Science-Projekte: Projektmanagement Frameworks



- Klassische Software-Entwicklungsframeworks lassen sich nicht 100% auf Data Science Projekte übertragen
- Höhere Unsicherheit und häufige Anpassungen benötigen kurze Iterationszyklen
- Aufwandsschätzung wegen hoher Unsicherheit nur schwer möglich

## TIPPS

- Der Unsicherheit mit klaren Fragestellungen begegnen und klare KPIs definieren.
- Timeboxing anstatt Aufwandsabschätzung – nach dem Timeboxing weiter entscheiden
- Frameworks nicht sklavisch verwenden sondern eher das Agile Manifest beachten.

## Manifesto for Agile Software Development

We are uncovering better ways of developing software by doing it and helping others do it.  
Through this work we have come to value:

**Individuals and interactions** over processes and tools  
**Working software** over comprehensive documentation  
**Customer collaboration** over contract negotiation  
**Responding to change** over following a plan

That is, while there is value in the items on the right, we value the items on the left more.

Kent Beck	James Grenning	Robert C. Martin
Mike Beedle	Jim Highsmith	Steve Mellor
Arie van Bennekum	Andrew Hunt	Ken Schwaber
Alistair Cockburn	Ron Jeffries	Jeff Sutherland
Ward Cunningham	Jon Kern	Dave Thomas
Martin Fowler	Brian Marick	

© 2001, the above authors  
this declaration may be freely copied in any form,  
but only in its entirety through this notice.

Online Session

## Von der Idee zum Datenprodukt

Was ist ein Datenprodukt?

Wie definiere ich Use Cases richtig?

Wie sieht das Setup erfolgreicher Data-Science-Projekte aus?

Wieso ist Kollaboration ein so wichtiger Erfolgsfaktor?

Wie gelingt die Überführung in das Daily Business?

### FRAGEN & ANTWORTEN

Wir freuen uns auf Ihre Fragen im Chat.



# Das Spannungsfeld in Data-Science-Projekten

## Management

„Das Projekt ist eine Investition. Wir erwarten einen schnellen Return on Investment.“

## Fachbereich


„Wir wollen schnelle Ergebnisse sehen“

## Data Science / Analysten

„Wir wollen Methoden / Technologien flexibel ausprobieren, um zur besten Lösung zu kommen“

## IT-Administration


„Achtet auf die Einhaltung von Standards und Regeln“



# Kollaboration und Kommunikation aktiv fördern

Etablierung von konkreten Kommunikations- und Zusammenarbeitsformaten in Data-Science-Projekten, Einbindung des Fachbereichs

- Gemeinsamer Kick-off
- Einführung in die Prozesse des Fachbereichs, um die aktuellen Arbeitsweisen zu verstehen
- Regelmäßige Alignment-Runden
- Einführung von „Übersetzungsrollen“



Online Session

## Von der Idee zum Datenprodukt

Was ist ein Datenprodukt?

Wie definiere ich Use Cases richtig?

Wie sieht das Setup erfolgreicher Data-Science-Projekte aus?

Wieso ist Kollaboration ein so wichtiger Erfolgsfaktor?

Wie gelingt die Überführung in das Daily Business?

### FRAGEN & ANTWORTEN

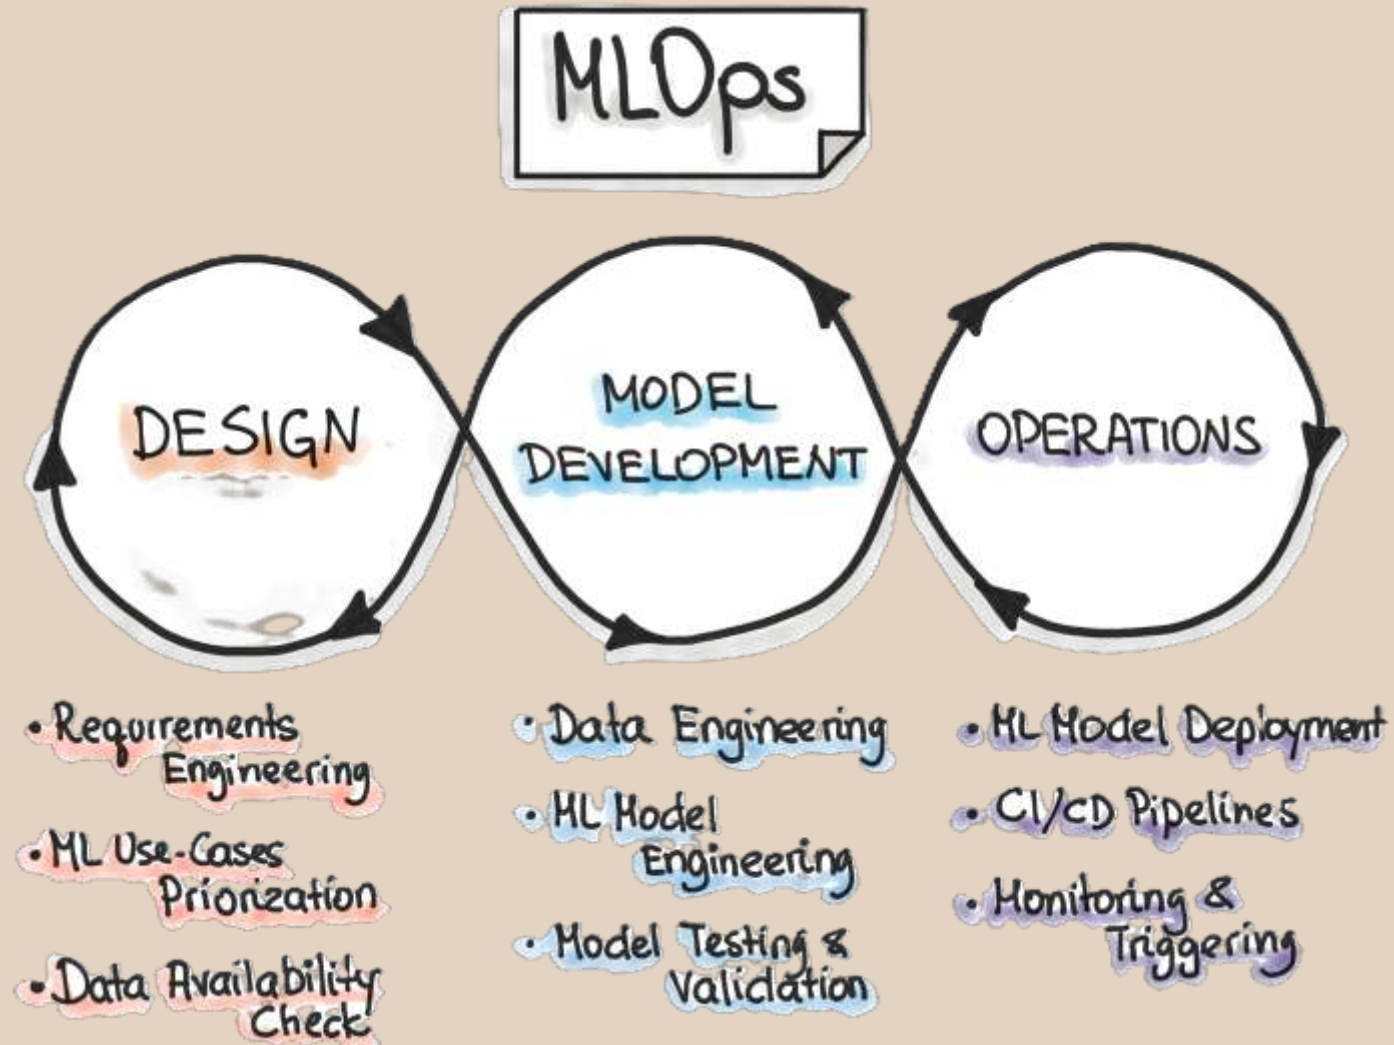
Wir freuen uns auf Ihre Fragen im Chat.



# Typische Fallen beim Deployment



# MLOps-Prozesse helfen bei der Überführung in den Produktivbetrieb



# Einführung eines Datenprodukts sollte durch Change Management begleitet werden

- Datenprodukte stiften nur dann nutzen, wenn sie eingesetzt werden
- Interpretation von Ergebnissen (z.B. Fähigkeit, in Wahrscheinlichkeiten zu denken)
- Begleitung der Einführung von Datenprodukten

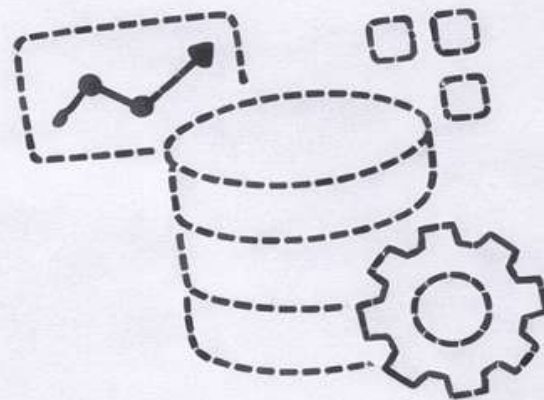
## Was kann man tun?

- Mitarbeitende aktiv mitnehmen
- Kommunizieren, Kommunizieren, Kommunizieren
- Schulungen
- Unterstützung anbieten
- Mit gutem Vorbild vorangehen.



# CHECKLISTE DATENPRODUKTE

- Use Case verfügt über einen klar definierten Scope
- Messbare KPIs zur Erfolgsbewertung sind definiert
- Alle relevanten Stakeholder sind eingebunden
- Strategie für Überführung in Produktivbetrieb ist erarbeitet



# eoda begleitet Sie von der Idee zum erfolgreichen Datenprodukt



# Ausblick: Unsere nächste Online Session

## Autoscaling trifft Analytics

Posit-Infrastrukturen im Kubernetes Cluster

19. Mai 2026 | 11-12 Uhr



Jetzt anmelden



**ONLINE  
SESSION**



Rückblick: Einblicke in zurückliegende Online Sessions erhalten Sie [hier](#).

Ihr Ansprechpartner für Ihren  
Deep-Dive in die Daten

Martin Schneider

Chief Data Scientist

+49 561 87948-370

[martin.schneider@eoda.de](mailto:martin.schneider@eoda.de)



eoda GmbH | Universitätsplatz 12 | 34127 Kassel

We are social

