

# Rise of Tech Conference

## MLOps – AI-Anwendungen im Team erfolgreich operationalisieren

Kurt Fritz  
Verbund Energy4Business  
Team Data Intelligence & Pricing  
17.06.2025



# Intro und Zielsetzung des Workshops

## Zielsetzung

Diskussion des Pfades von der ML-Idee zum operativ laufenden KI-Modell

---

## Fokus

Konzeptionelle Ansätze und Prinzipien

- Keine spezifischen Technologie- oder Anbieterdiskussionen
  - Beispielmodell für Veranschaulichungen und Erfahrungen
- 

## Interaktiver Austausch

Kurze thematische Impulse mit Folien, gefolgt von gemeinsamer Diskussion

---

## Mein Hintergrund

Studium Mathematik und Physik  
12 Jahre Erfahrung in der Energiewirtschaft

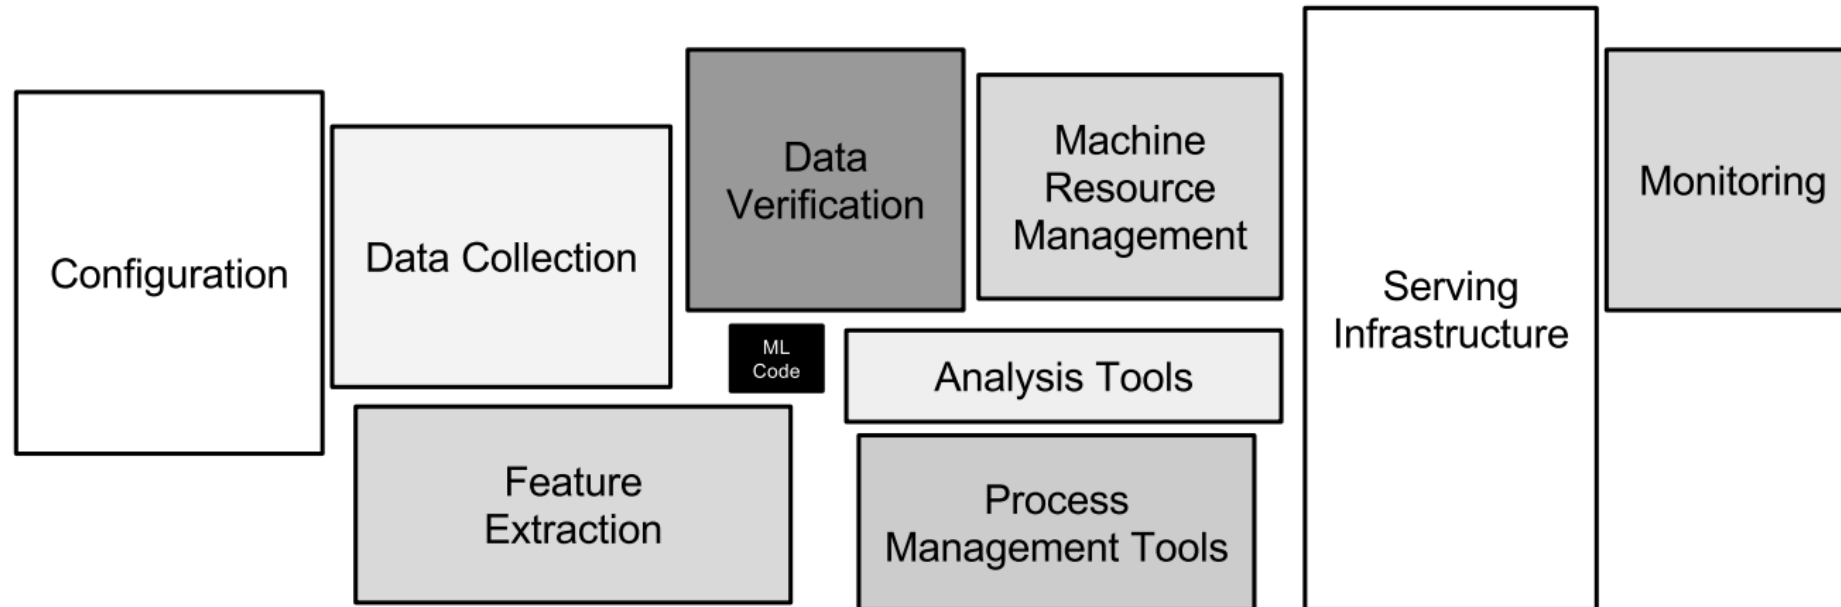
---

## Team


Team Data Intelligence und Pricing  
Wir schaffen maßgeschneiderte quantitative Lösungen für Handel, Vertrieb und Asset-Vermarktung von Verbund Energy4Business

# Hidden Technical Debt in Machine Learning Systems

*Technical Debt (Technische Schuld) ... zusätzlicher Aufwand, den man für Änderungen und Erweiterungen an schlecht geschriebener Software im Vergleich zu gut geschriebener Software einplanen muss.*



# Skillsets Machine Learning Realisierung und Betrieb



## Data Engineering

Aufbau und der Wartung von Infrastruktur und Prozessen, um Daten zuverlässig zu sammeln, zu transformieren, zu speichern und für Analyse und Training aufzubereiten



## Data Analysis

Untersuchung, Bereinigung, Transformation und Modellierung von Daten, um nützliche Informationen, Zusammenhänge und Schlussfolgerungen aufzudecken



## ML-Engineering

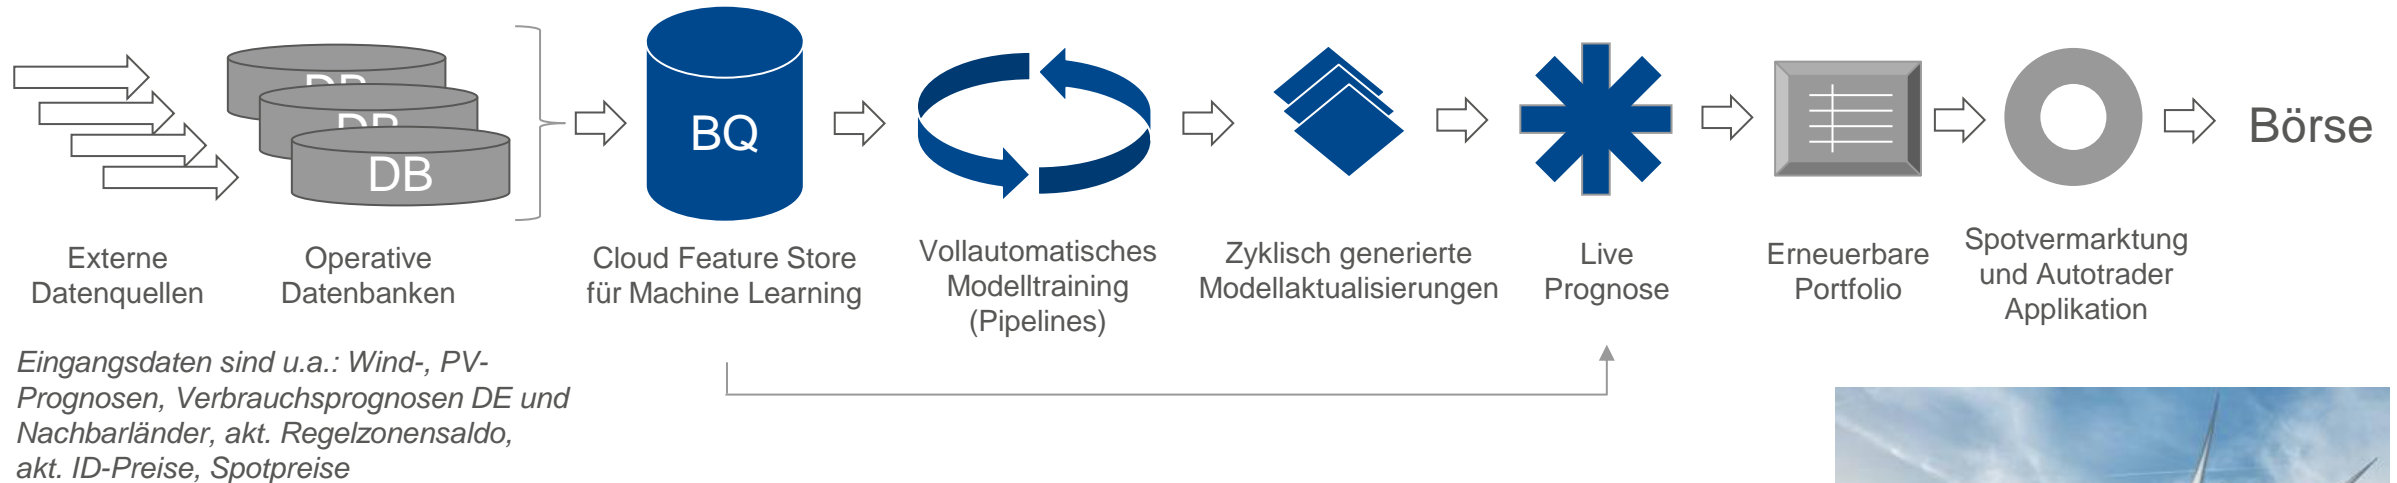
Aufbau, Bereitstellung und der Wartung von skalierbaren, zuverlässigen und automatisierten Pipelineprozessen für Machine Learning Modelle



## Software Engineering

Entwicklung robuster, skalierbarer und wartbarer Softwareinfrastruktur und -prozesse, um ML-Modelle zuverlässig in Produktionsumgebungen bereitzustellen und zu verwalten

# Illustrierender Beispiel-Case: Integration ML-Modell in operativen Workflow Erneuerbare Energien



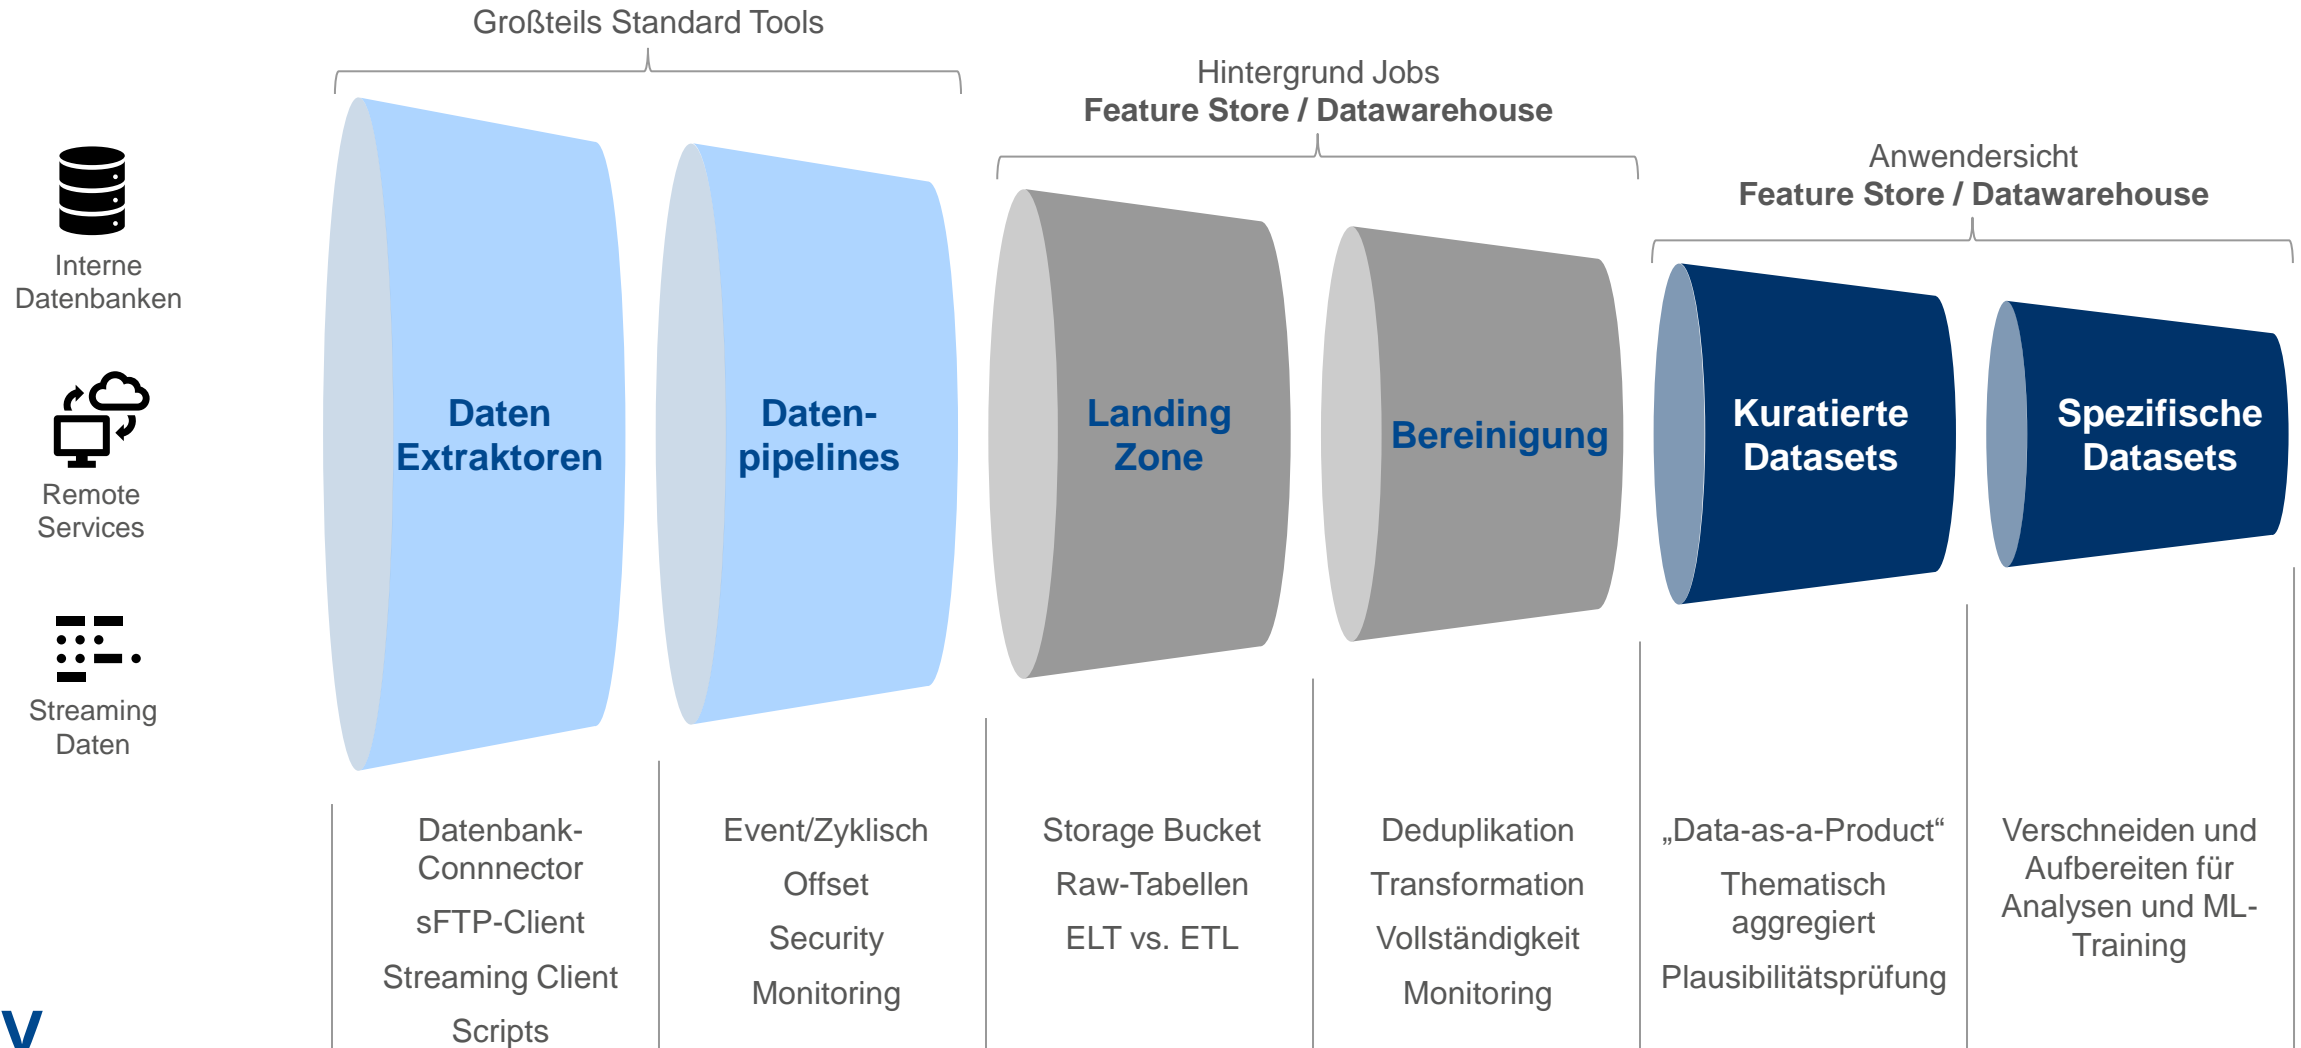
## Nutzung der Cloud als Machine Learning Infrastruktur

- Selbstverwaltet im Team
- Vorbildwirkung für Infrastruktur as Code und agiler Cloud-Nutzung (MLOps-Prinzip)
- Nutzung von State-of-the-Art AI-Technologien
- Serverless Architektur mit flexibler Ressourcenskalisierung und hoher Verfügbarkeit
- Enge Anbindung an Verbund Infrastruktur bei gleichzeitiger Abschottung nach außen




Anmerkung: Erster Usecase in der neu aufgebauten Umgebung (ab 2020)

# Solides Data Engineering als Fundament



# Data Analysis mit Domain Knowledge



## Feature Store als Ausgangspunkt:

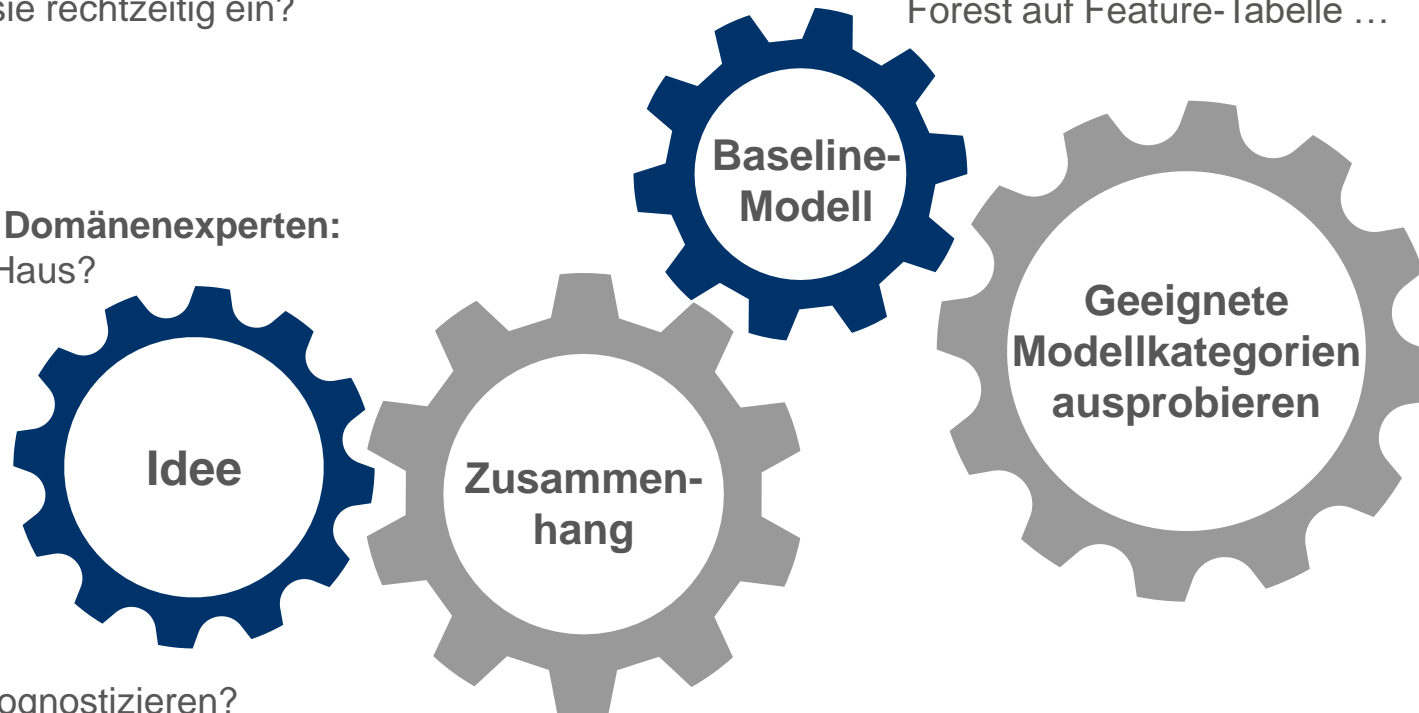
Haben wir die Daten?  
Treffen sie rechtzeitig ein?

## Einfach aber nicht zu einfach:

Was schafft ein einfach zu implementierendes Modell?  
Z.B. letzten Wert fortschreiben, lineares Modell, Random-Forest auf Feature-Tabelle ...

## Kommunikation mit Domänenexperten:

Gibt es Expertise im Haus?  
Bekannte Einflüsse?



## Recherche

Regression vs. Klassifikation  
Auto ML  
Feature-Engineering  
Zeitreihenmodelle, Bilder ...

## Eingrenzung:

Was genau will ich prognostizieren?  
Wann genau möchte ich die Prognose erhalten?  
Zeitintervall, Wert/Kategorie ...  
Definitionen schärfen

## Kausalität vs. Korrelation:

z.B.: Eiscremeverkäufe und Ertrinkungsunfälle  
Plots, KPI, Zeiträume, Ausnahmesituationen etc.

# ML-Engineering – Realismus und Plausibilität



## Experimentierumgebung

Vom Analyseergebnis zum Modell

**Wichtig: Freiheit aber Kompatibilität!**

z.B. jupyter-Notebooks

**Überwachung des Modellerfolgs**

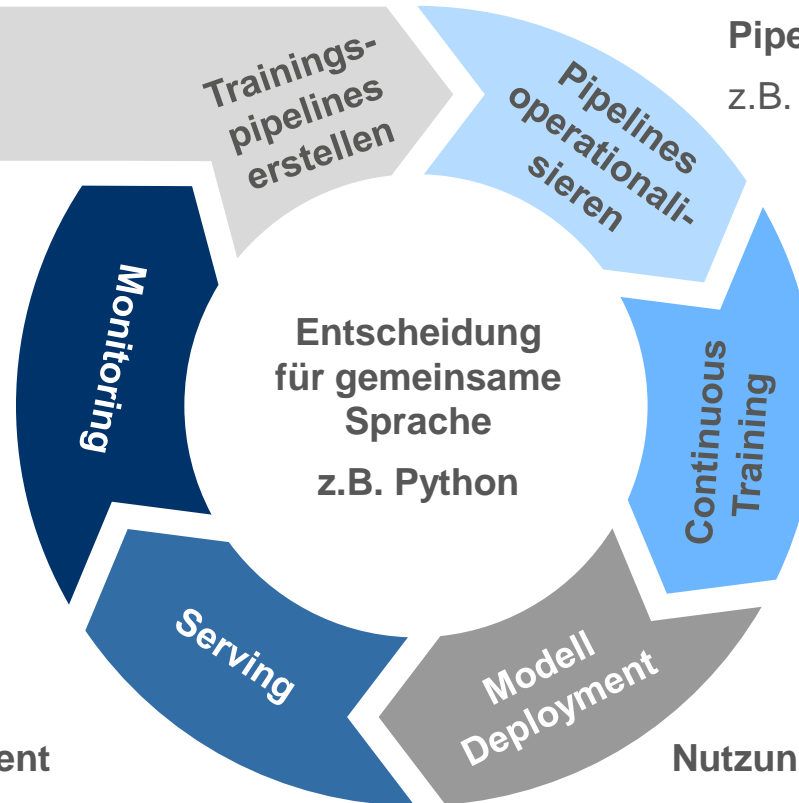
z.B. Handelserfolg festgehalten

Messbarkeit

**Scheduler oder Event**

z.B. zyklischer Aufruf python-Script

Reaktion auf Streaming Event



**Pipelines in Laufzeitumgebung ausführen**

z.B. Kubeflow-Pipelines auf Kubernetes

**Aktualisierung der Datenbasis**

z.B. Wöchentliche Anpassung Trainingsfenster

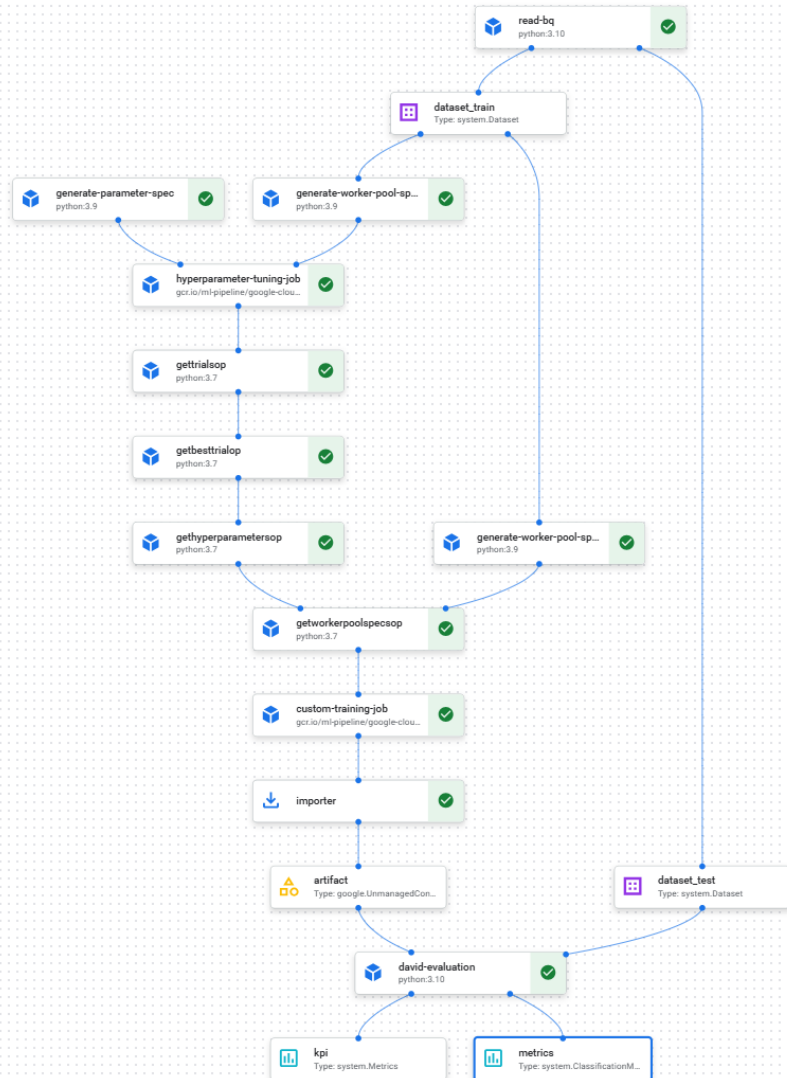
Modelle versionieren

**Nutzungshäufigkeit & Hosting-Kosten**

Docker-Image & Serverless Cloud vs.

Modell bei Bedarf aus Speicher laden

# ML-Engineering – Die konkrete ML-Pipeline Überlegungen und Fragestellungen



## Komplexes oder einfaches Modell?

- Bestmögliche Vorhersagequalität?
- Robust im operativen Betrieb?
- Feature-Pflegeaufwand?

## Was ist das Maß für ein gutes Modell?

- Handelsergebnis insgesamt oder konstanter Zuwachs?
- Kontinuierlicher Ergebnisbeitrag über lange Zeiträume?

## Was wird in der Trainingspipeline benötigt?

- Modelltyp-Selektion?
- Feature Engineering
- Hyperparameterertuning?
- Modellevaluation?
- Qualitätscheck?

## Ist das Gesamtsetup in sich schlüssig oder gibt es Problemstellen?

### Wo läuft die Pipeline?

- Kubernetes/Cloud/Lokal?
- Abhängigkeiten von Infrastruktur/Package-Versionen?

## Wo werden die trainierten Modelle verwaltet?

## Wie erfolgt das Serving?

- App/Service/Individueller Aufruf?

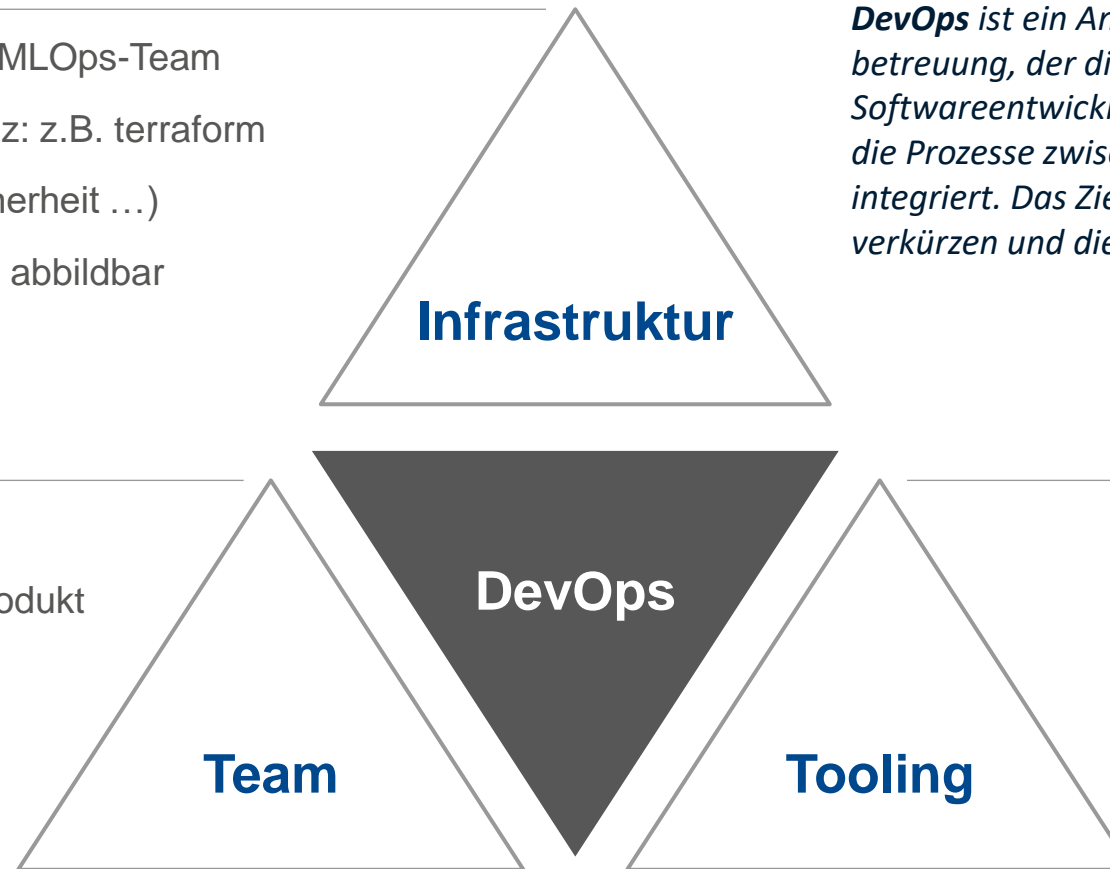
## Metadatenmanagement und Qualitätssicherung?

- Welche Prognose wurde mit welchem Modell gerechnet?

# Software Engineering – Nutzen von Erfahrung aus DevOps-Ansatz

- Abgestimmter Rahmen („Bubble“) für MLOps-Team
- Infrastructure-as-Code für Transparenz: z.B. terraform
- IT-Security (Package-Scan, Datensicherheit ...)
- Ziel: Idee bis Live-Betrieb durch Team abbildbar

- Rollen/Skillsets vs. Personen
- Eigenverantwortlichkeit für das Endprodukt
- Spezialisten mit breiter Basis
- Arbeitsmodus (Sprints, Kanban...)
- Übergabepunkte
- Vertretungsregelungen



*DevOps ist ein Ansatz zur Softwareentwicklung und -betreuung, der die Zusammenarbeit zwischen Softwareentwicklungs- und IT-Betriebsteams fördert und die Prozesse zwischen diesen Teams automatisiert und integriert. Das Ziel ist, die Zeit vom Code zur Produktion zu verkürzen und die Qualität der Software zu verbessern.*

- Gemeinsame Umgebung
- Source Code Verwaltung (Git etc.)
- CI/CD
- Statische Code-Analyse

# Ausblick: MLOps für Generative AI und Agents (GenAIOps)

Modell-Ebene:


Provider

Fine-Tuner


Applikationsentwickler




Data Engineering



Data Analysis



ML-Engineering



Software Engineering

Agent-Ebene:

Prompt-Engineering

RAG (Retrieval-Augmented Generation)

Function Calling

Agent Testing

MCP (Model Context Protocol) Server

Agent Security

# Vielen Dank!



Verbund



**Mag. Kurt Fritz , MSc**

Teamleiter Data Intelligence  
Portfolio Management and Energy  
Economics

 VERBUND Energy4Business GmbH



<https://vcard.verbund.com/kurt.fritz-0FIKE>