



## Streamlit for Rapid MVPs - Experiences and Next Steps

# Wer spricht hier?



- Marc Siggelkow
  - Wirtschaftsinformatik  
an der HTW Dresden
  - Data Scientist / Analyst

marc.Siggelkow@packwise.de  
www.packwise.io



**01** Packwise

**02** Das Problem

**03** Streamlit

**04** Examples

**05** Next Steps



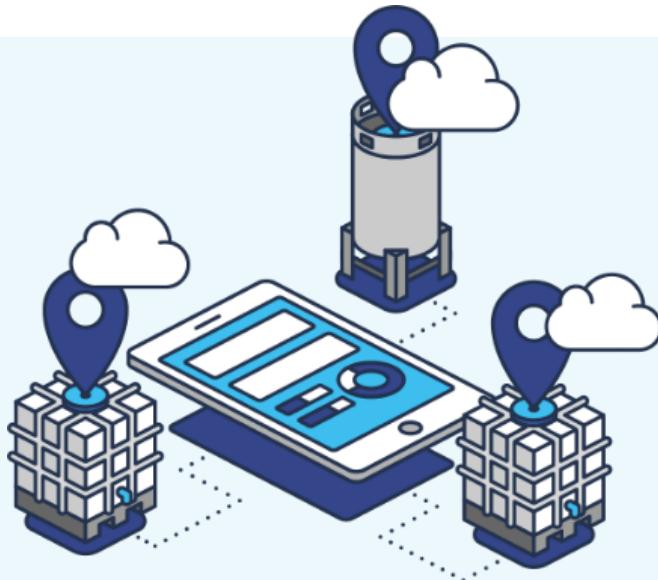
# 01

## Packwise



# Packwise

Containerflossen intelligenter steuern - dank **Packwise Flow**



# Packwise

Welche Container tracken wir?

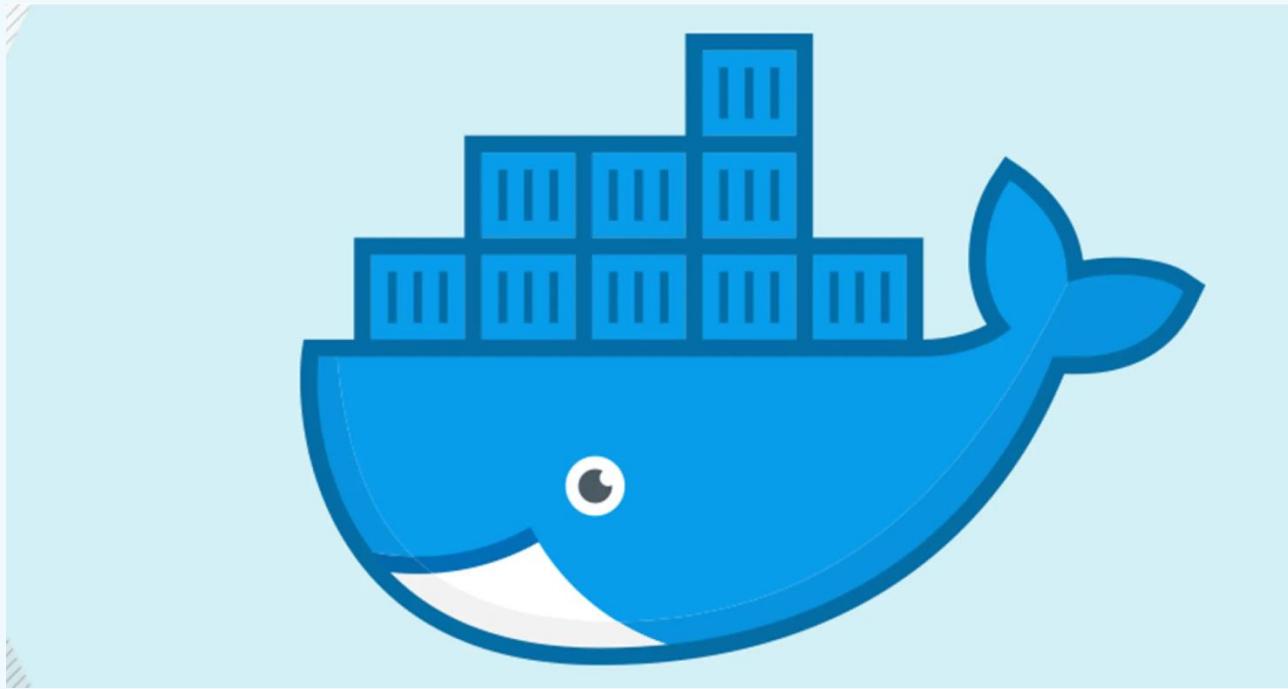


... nicht diese

# Packwise

Welche Container tracken wir?

---



... auch nicht diese

# Packwise

Welche Container tracken wir?

---



... und viele mehr!

## pack:wise flow



## pack:wise *smart cap*



# Packwise

## Die Smartcap – das IoT-Device



**Packwise Smart Cap**  
Create a unique data set



Pressure



Damage



Location



Movement



Temperature



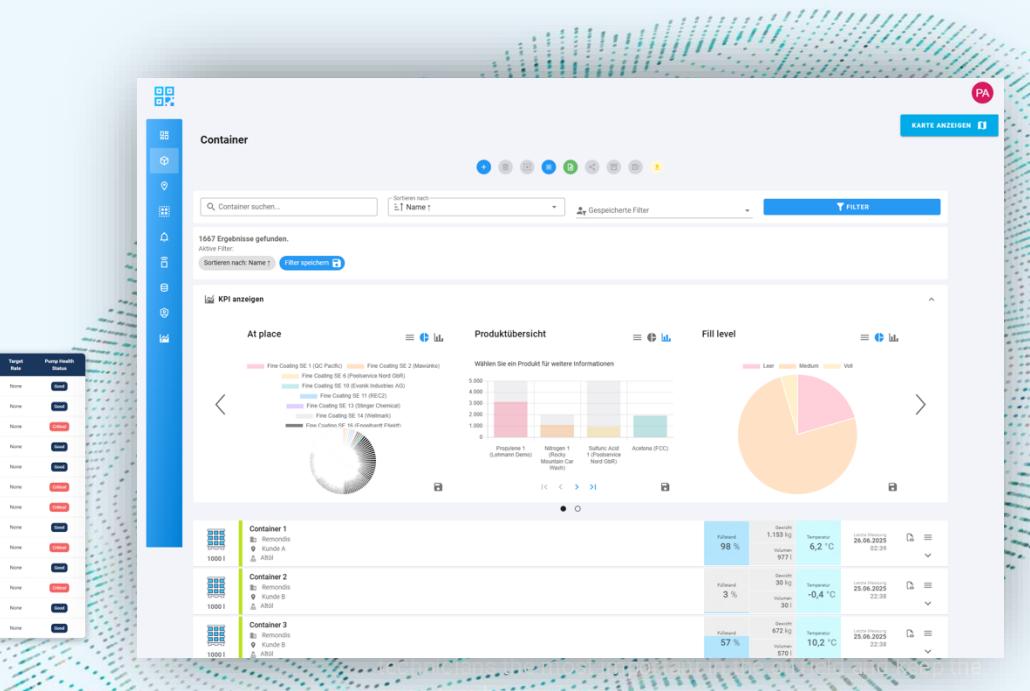
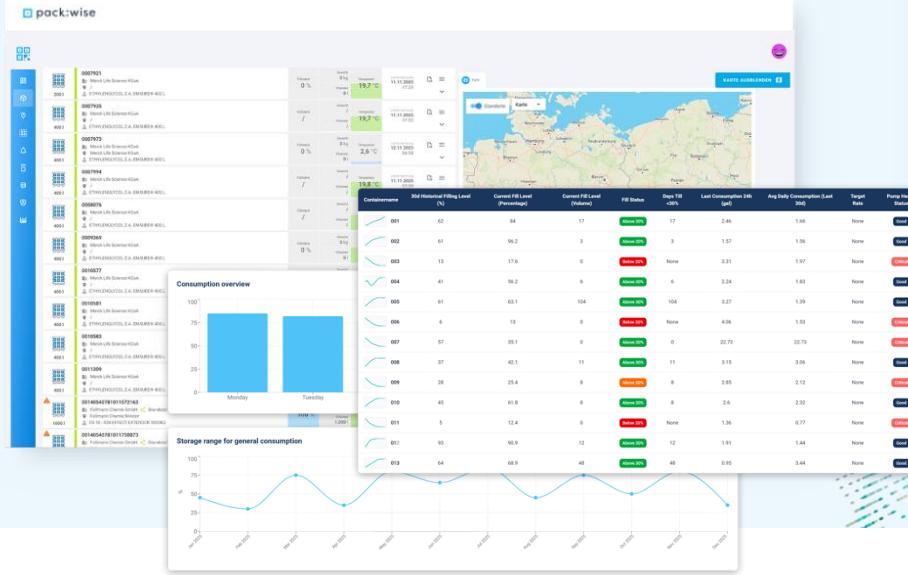
Filllevel



**Packwise Flow**  
Turn it into valueable insights

# Packwise

## Packwiseflow – die Software Anwendung



# 02

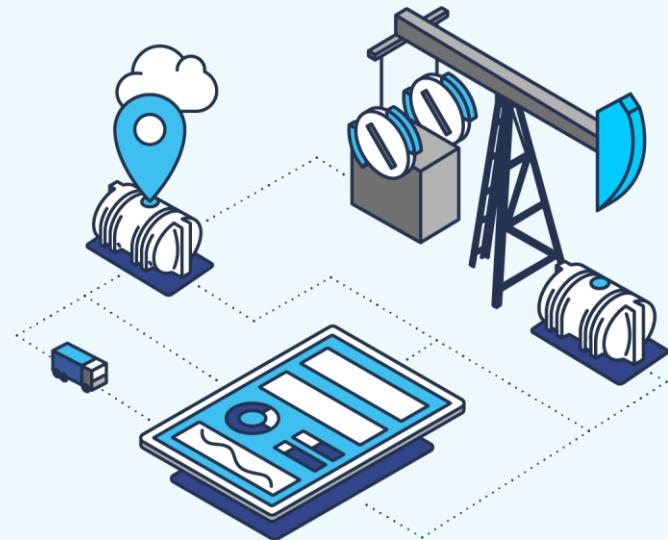
## Das Problem



# Das Problem

## Der Ausgangszustand

- **Erreicht:** Volle Transparenz über Position (GPS) und Füllstand (Radar).
- **Problem:** Reine Darstellung von Ist-Zuständen ohne Kontext.
- **Status:** „Data Rich, Insight Poor“ – Wir haben die Daten, aber noch keine Antworten.
- **Ziel:** Den Sprung vom passiven Monitoring zur aktiven Logistiksteuerung schaffen.



# Das Problem

## Status Que

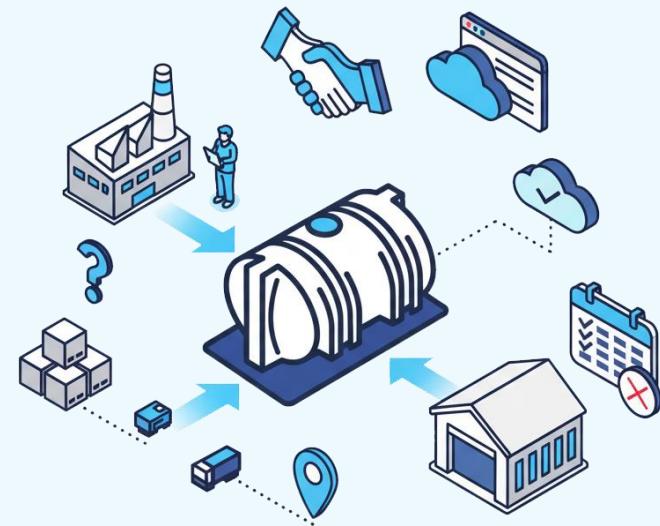
- **Deskriptive Daten sind vorhanden:** Wir wissen, wo der Container ist und *wie viel* drin ist (Status Quo).
- **Die „So-What?“-Lücke:** Kunden sehen Punkte auf einer Karte, können aber ihre Supply Chain noch nicht aktiv steuern.
- **Das versteckte Potenzial:** Die DB füllt sich mit wertvollen Zeitreihen, aber die geschäftskritischen Antworten (Umlaufgeschwindigkeit, Bedarfsprognose) fehlen.



# Das Problem

## Der nächste Schritt

- **Nicht-artikulierte Anforderungen:** Kunden können ihren Bedarf erst benennen, wenn sie erste Analysen sehen.
- **Explorationsphase:** Welche KPIs (z. B. Umlaufgeschwindigkeit, Restlaufzeit-Prognose) liefern den größten Business-Value?
- **Das Risiko des „Over-Engineering“:** Monate an Entwicklung für ein Feature zu investieren, das am Ende niemand nutzt.



# 03

## Streamlit



# Streamlit

## Was ist das?

---

**Definition:** Open-Source Python-Framework zur Erstellung interaktiver Web-Apps für Data Science.

**Das Paradigma: Scripting statt Callbacks**

- Keine Trennung von Frontend (HTML/CSS/JS) und Backend.
- Die gesamte App ist ein einziges Python-Skript.
- Reaktives Ausführungsmodell: Bei jeder Nutzerinteraktion wird das Skript von oben nach unten neu ausgeführt.

**Core Features:**

- **UI als Code:** Widgets (Slider, Buttons, Inputs) werden direkt als Variablen definiert (`x = st.slider(...)`).
- **Native Integration:** Nahtlose Unterstützung für Pandas, Plotly, Altair, Matplotlib und PyTorch.



# Streamlit

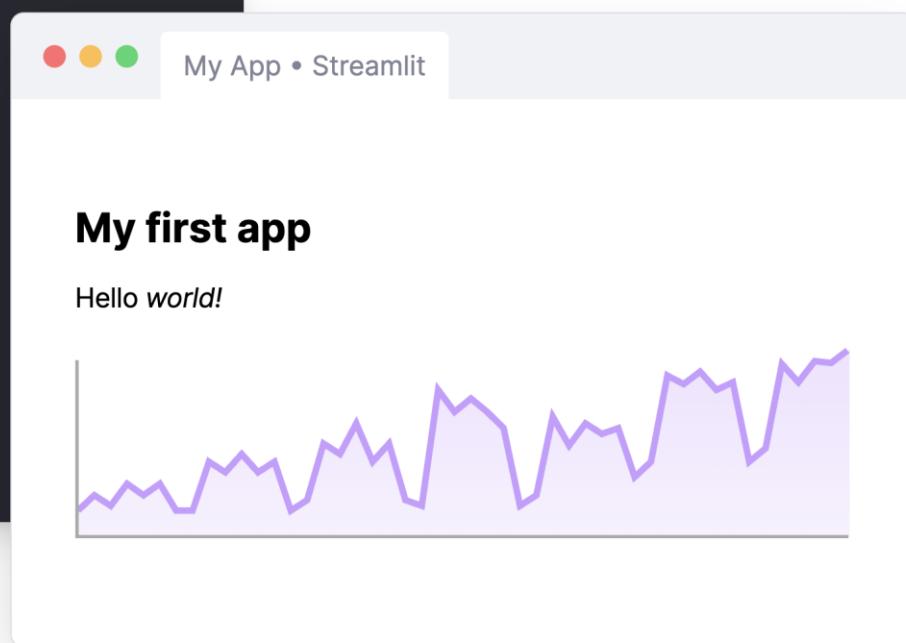
## Simple Streamlit App

MyApp.py

```
import streamlit as st
import pandas as pd

st.write("""
# My first app
Hello *world!*
""")

df = pd.read_csv("my_data.csv")
st.line_chart(df)
```



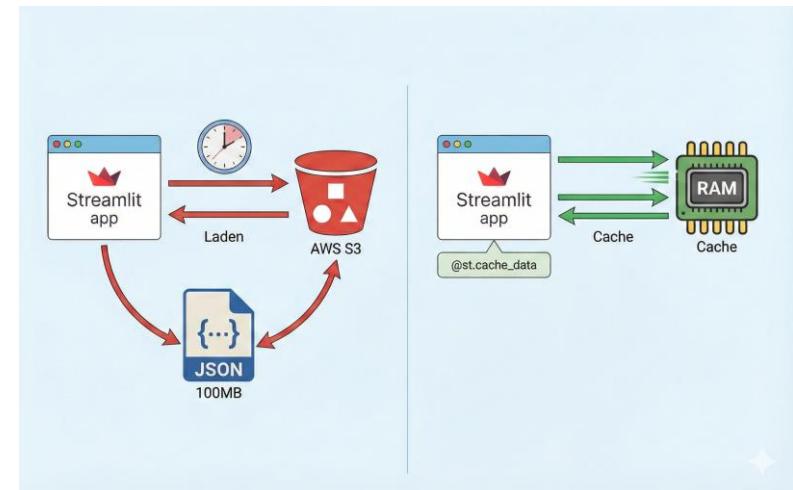
# Streamlit

## st.cache\_data

- **Das Problem:** Große Datensätze (z.B. 100MB+ Json File von S3) führen bei jedem Re-Run zu Latenzen.
- **Naive Lösung:** Daten bei jedem Klick neu laden -> Schlechte UX, hohe S3-Kosten, Server-Last.

### Die Lösung: @st.cache\_data

- Speichert das Ergebnis einer Funktion im RAM.
- **Hashing-Prinzip:** Streamlit prüft die Eingabeparameter. Sind sie gleich, wird das Ergebnis sofort aus dem Cache geladen.



# Streamlit

## Statemanagement

---

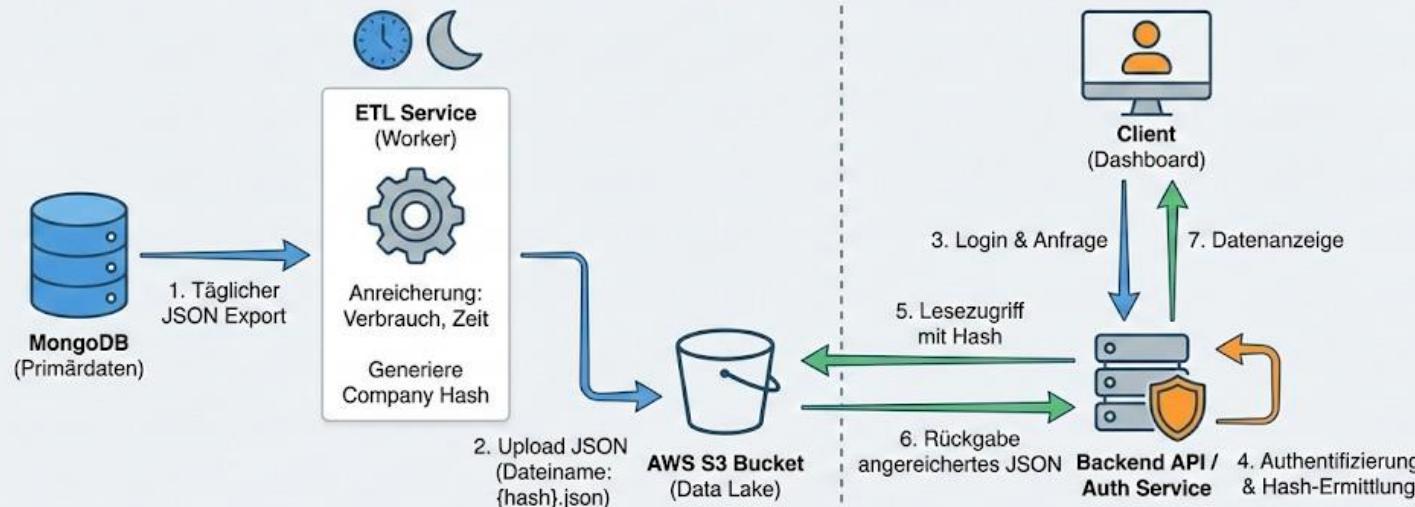
- **Das Re-Run Prinzip:** Jede Interaktion (Button, Slider, Input) löst eine komplette Neu-Ausführung des Python-Skripts aus.
- **Die Herausforderung:** Lokale Variablen gehen bei jedem Re-Run verloren.
- **Die Lösung: `st.session_state`**
  - Ein Dictionary-ähnliches Objekt, das über die gesamte Nutzer-Session hinweg persistent bleibt.
  - Ermöglicht komplexe Workflows (z.B. Multi-Step-Filter, Login-Status, Caching von User-Eingaben).

# Streamlit

## Die Architektur

### Architektur: Datenaufbereitung & Sicherer Dashboard-Zugriff

#### PHASE 1: Nächtliche Datenaufbereitung (Asynchron)



# 04 Examples



# Oil & Gas

## Messbare Mehrwerte & Effizienzgewinne

TANK	PRODUCT	PLACE	MAX VOL.	FILL. HIST.	FILL %	FILL VOL.	FILL STATUS	PUMP STATUS	CONS. LAST DAY	DAYS TILL 30%	DATE
TANK001	Hydraulic Fracturing Fluid	Eagle Ford Drilling Platform A	135		74	100	<span>ABOVE 30%</span>	<span>NORMAL</span>	3	20	2024-10-15
TANK043	Hydraulic Fracturing Fluid	West Texas Crude Site 2	135		79	106	<span>ABOVE 30%</span>	<span>NORMAL</span>	8	8	2024-10-23
LOWCONS085	Drilling Lubricant DL-50	Woodford Shale Platform TX	135		97	131	<span>ABOVE 30%</span>	<span>NORMAL</span>	1	14	2024-10-16
TANK042	Drilling Lubricant DL-50	Delaware Basin Rig West-1	135		29	39	<span>BELOW 30%</span>	<span>NORMAL</span>	7	0	N
TANK041	Corrosion Inhibitor Cl-200	Austin Chalk Platform Alpha	135		12	16	<span>BELOW 20%</span>	<span>NORMAL</span>	3	0	N
TANK040	Drilling Mud Additive	Haynesville Rig Houston-1	135		82	111	<span>ABOVE 30%</span>	<span>NORMAL</span>	5	14	2024-10-21
BROKEN086	Completion Fluid CF-100	Delaware Basin Rig West-1	135		48	65	<span>ABOVE 30%</span>	<span>TO BE CHECKED</span>	0	113	2024-10-17
TANK039	Hydraulic Fracturing Fluid	Permian Basin Site Beta	135		24	32	<span>BELOW 30%</span>	<span>NORMAL</span>	5	0	N

# Oil & Gas

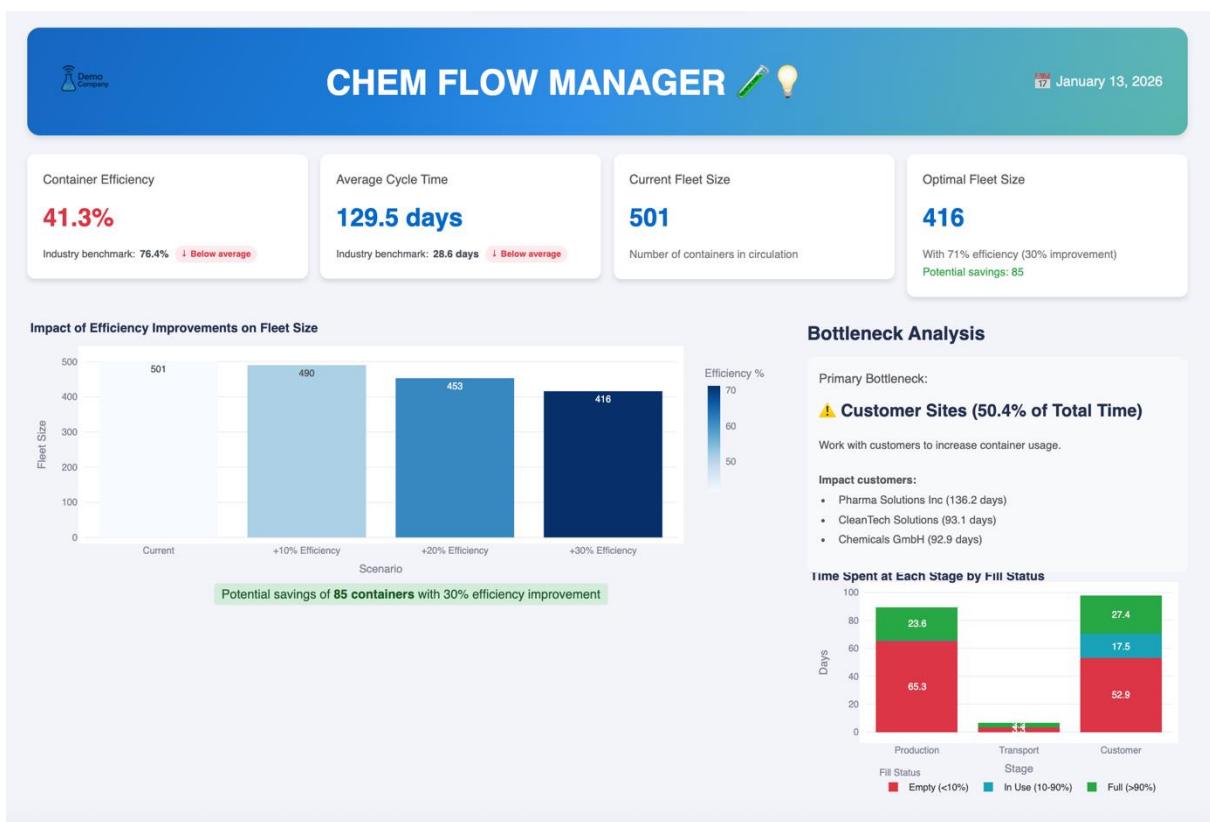
## Messbare Mehrwerte & Effizienzgewinne

### Consumption Forecast



# Fleet Size Manager

## Messbare Mehrwerte & Effizienzgewinne



# Examples

## Der iterative Workflow

---

**Traditioneller Weg:** DB-Schema ändern → ETL  
anpassen → API erweitern → Frontend bauen →  
Deployment (Wochen).

**Der Streamlit-Weg:** Logik im Python-Script anpassen  
→ Git Push → Live (Minuten).

**Vorteil:** Keine Datenbank-Migrationen oder Re-Seeding  
notwendig, da wir die Transformation „on-the-fly“ im  
Script machen.

# 05

## Next Steps

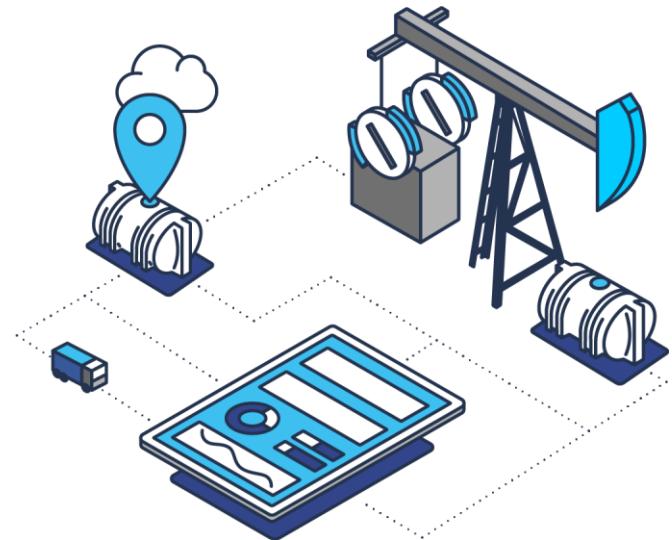


# Next Steps

## Anzahl der Datenpunkte

---

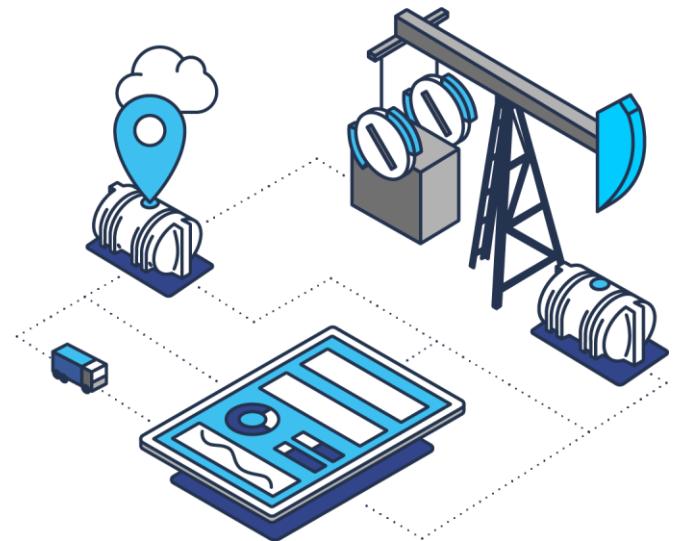
- **12.000+** aktive Smartcaps im Feld.
- **~3 Messungen** pro Tag
- **> 13 Mio.** Datenpunkte pro Jahr



# Next Steps

## Wenn das MVP an Grenzen stößt

- **Performance:** Millionen von Zeilen in Pandas zu prozessieren, treibt den RAM des Servers ans Limit
- **Latenz:** Der Datentransfer von S3 zum Client (Streamlit) wird bei wachsender Historie spürbar langsam.
- **Multi-Tenancy & Security:** Das Management von hunderten S3-Hashes und Customer-IDs wird im Code unübersichtlich.
- **Wartbarkeit:** „Spaghetti-Code“ in den Streamlit-Skripten durch zu viel Logik im Frontend-Bereich.

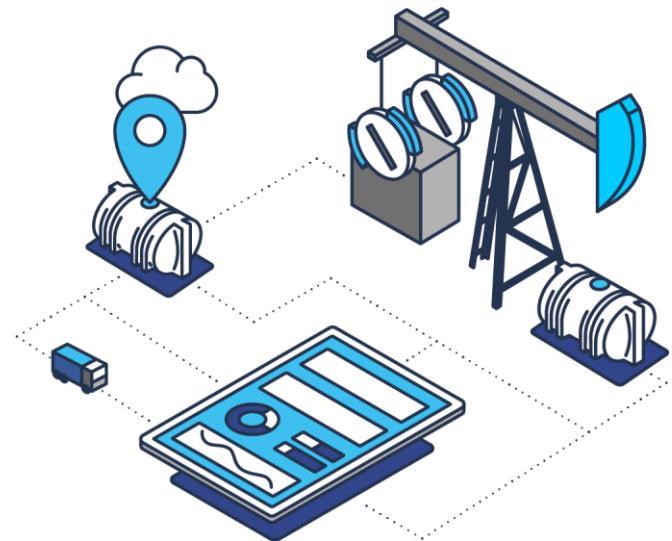


# Next Steps

## Wenn das MVP an Grenzen stößt

- **Storage:** Umstieg von S3-Dateien auf **AWS Redshift** (Cloud Data Warehouse).
- **Compute:** Logik wandert vom Python-Client in die Datenbank (SQL-Aggregationen).
- **ETL-Strecke:** Automatisierte Pipelines statt einfacher JSON-Dumps.

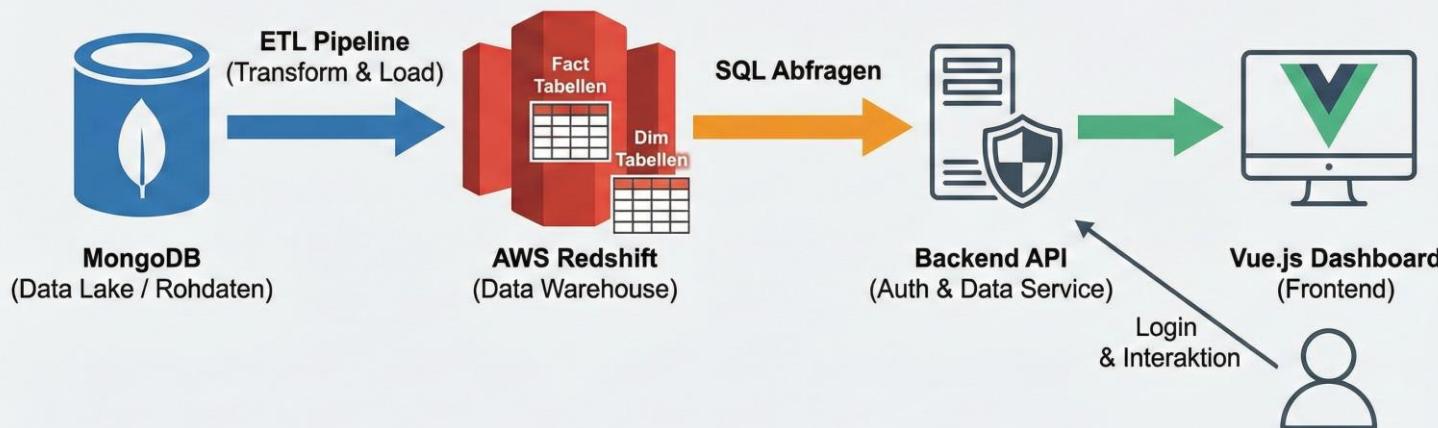
**Streamlit** bleibt für Data Science Prototypen, Spezial-Tools und neue MVP's



# Next Steps

## Die Architektur

### Neue Architektur: Data Lake to Vue Dashboard



Datenfluss: Rohdaten -> ETL -> Redshift (Fact/Dim) -> Backend API -> Vue Dashboard

# Next Steps

## Build to learn, not to scale

---

**Zentrales Learning:** „Scale what works – discard what doesn't.“ und Perfekt ist der Feind von Gut

**Startup-Mentalität:** Geschwindigkeit ist eine Ressource, Perfektion am Anfang ein Hindernis.

**Empfehlung für Studenten:** Nutzt Tools wie Streamlit, um Ideen sofort greifbar zu machen. Datenbanken sind das Fundament, aber die App ist das Fenster zum Nutzer.



Vielen Dank

Fragen?