

Herzlich Willkommen zur Online Session –  
gleich geht es los

# Zero-Shot Time-Series Forecasting: Prognosen von Zeitreihen ohne Trainingsdaten



Ihr Experte

**Matthias Henneke**

Senior Data Scientist

Leitfragen der Online Session

## Zero-Shot Time-Series Forecasting (ZSTSF)

**Was ist ZSTSF?**

**Wann sollte ich ZSTSF nutzen?**

**Wie funktioniert ZSTSF?**

**Wie gut funktioniert ZSTSF?**

### **FRAGEN & ANTWORTEN**

Wir freuen uns auf Ihre Fragen im Chat.



„Unternehmen verfügen über große Datenmengen.

Wieso nutzen sie das darin enthaltene Wissen nicht besser?“

—  
Mitgründer & CEO Oliver Bracht | 2010

**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



Über mich

## Matthias Henneke

Senior Data Scientist | eoda | Kassel

Tätigkeitsfelder:

- Leitung und Umsetzung von Data-Science- und GenAI-Projekten
- Data-Science-Trainer

> 8 Jahre Praxiserfahrung als Data Scientist (u.a. bei Check24)






# Zeitreihen sind sehr verbreitet


- Maschinensensordaten
- Energieverbrauch
- Verkaufszahlen
- Logging
- Verkehrsaufkommen
- ...



# Zeitreihenmodelle: Rasante Entwicklung


|                           | 2000/2010er   | 2017-2023  | Seit 2024   |
|---------------------------|---|--|---|
| <b>Methoden</b>           | Statistik & ML  | Neuronale Netze  | Foundation Models   |
| <b>Konkrete Modelle</b>   | ARIMA, XGBoost  | DeepAR, N-Beats, TFT   | TimeGPT, TimesFM  |
| <b>Modell : Zeitreihe</b> | <br>Ein Modell pro Zeitreihe | <br>1:N<br>Ein Modell pro Datensatz | <br>1: ∞<br>Ein Modell für alles |
| <b>Modelltraining</b>     | Einzelne Zeitreihe  | Großer Datensatz   | Pretrained /Zero Shot   |
| <b>Datenbedarf</b>        | 1 lange Zeitreihe   | N lange Zeitreihen   | Kurzer Kontext  |
| <b>Hardware</b>           | CPU   | GPU (CPU)  | GPU (CPU)   |

**2026**  
Agentic Time Series Foundation Models



# Zero-Shot, wenn keine Daten für Few-Shot

## Zero-Shot Time-Series Forecasting

- Time-Series 
- Forecasting: Fortschreibung d. Zeitreihe
- Zero-Shot: Inferenz durch betriebsfertiges Modell

Lernparadigma

Größe Trainingsdaten

**Zero-Shot**

**0** (nur Kontext)

**Few-Shot / Transfer Learning**

Klein, wenige Beispiele

**Many/Full-Shot**

Viele, lange Zeitreihen

Trainingsdaten vorhanden?



ZS Modelle

DL/ML + ZS



# Wie funktioniert ZSTSF? Ein Ziel - viele Methoden.

## Auswahl an Ansätzen

- Native LLMs
- Value-Patching
- Time-Patching
- Time-Patching & Group-Attention
- Agentic Forecasting

# 1

## Native LLMs

**Idee:** LLMs haben beim Training notwendige Fähigkeiten bereits gelernt  
→ Mustererkennung und Sequenzverarbeitung durch LLMs  
→ Next Token Prediction

```
llm4ts_prompt_template = PromptTemplate.from_template("""  
Gegeben ist eine Zeitreihe :  
{context}  
  
Bitte prognostiziere die nächsten {horizont} Werte. Gib nur die Zahlenwerte  
zurück, getrennt durch Kommas.  
""")
```

**OpenAI**

 Meta AI  
**LLaMA**

**Gemini**

  
Gemma



**Qwen**

## 2

# Value Patching / Horizontal Binning

**Idee:** Quantisierung (Binning) der Zeitreihen

- Vorhersage von Zeitreihentoken durch Sprachmodell-Architektur (T5)
- Trainiert auf großem Korpus historischer und synthetischer Zeitreihen



Speziellere Aufgabe als LLM = kleinere Modelle möglich

Weniger Aufwand bei Training und Inferenz - Millionen (M) statt Milliarden (B) Parameter

# 3

## Time-Patching / Vertical Binning

**Idee:** Zerlegung von Zeitreihe in kleine Segmente (Patches)

- Das Modell lernt zukünftige Patches basierend auf vorherigen vorherzusagen

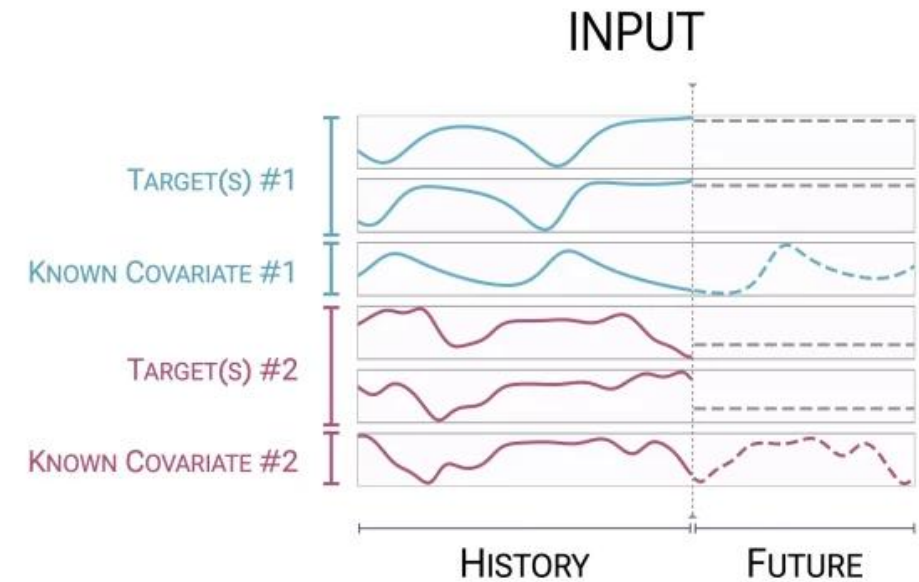


# 4

## Time-Patching + Group Attention

### Idee: Abwechselnd Patching und Group Attention Schritte


- Patching: Informationen aus vergangenen Zeitpunkten
- Group Attention: Informationen aus parallelen Zeitreihen (Covariates)
  - Wetterdaten, Timestamp-Features, Sensordaten etc.



TIME ATTENTION



GROUP ATTENTION



<https://arxiv.org/abs/2510.15821>

# 5

## Agentic Time-Series Forecasting


### Idee: LLM + Ensemble von ZSTSF-Modellen

- LLM steuert Modellauswahl
- Auswahl über Test-Split
- Flexibilisierung mittels Prompting möglich
- Deutlich höhere Latenz
  - LLM-Call
  - Mehrfache Inferenz

```
time_copilot = TimeCopilot(llm="openai:gpt-5-mini")
result = time_copilot.forecast(
    df=df,
    freq="15min",
    seasonality=7 * 24 * 4,
    h=2 * 24 * 4,
    query="Make a forecast with low MAE",
)
```

# Wie gut funktioniert ZSTSFS?

- 1. Paper zum Modell
  - Jedes Modell ist scheinbar besser als „SOTA“
  - Kein umfassender/aktueller Vergleich
- 2. Leaderboards
  - Statischer Evaluationsdatensatz
  - teilweise Test Leakage
- 3. Benchmarking auf privatem Datensatz
  - Garantiert nicht im Training gesehen
  - Passend zu Ihrem Use-Case!
  - Hilfreich beim Sammeln von Praxisproblemen



# GIFT-Eval Time Series Forecasting Leaderboard

We introduce the General Time Series Forecasting Model Evaluation, GIFT-Eval, a pioneering benchmark aimed at promoting evaluation across diverse datasets. GIFT-Eval encompasses 24 datasets over 144,000 time series and 177 million data points, spanning seven domains, 10 frequencies, multivariate inputs, and prediction lengths ranging from short to long-term forecasts.

[Overall](#) [By Domain](#) [By Frequency](#) [By Term Length](#) [By Variate Type](#) [About](#)

Search  
Separate multiple queries with ','

Select Columns to Display:  
 Organization  Test Leak.  Replication Code  MASE  MASE\_Rank  
 CRPS  CRPS\_Rank

Model types  
 agentic  zero-shot  pretrained  deep-learning  
 statistical  fine-tuned

Test Leak.  
 No  Yes

Replication Code  
 No  Yes

Show Rows with the Following Values

| T | model                                      | Organization                                | Test Leak. | Replication Code | MASE  | MASE_Rank |
|---|--|---|------------|------------------|-------|-----------|
| 🟡 | <a href="#">MoiraiAgent-leaking (code)</a> | Salesforce AI Research                      | Yes        | Yes              | 0.679 | 10.495    |
| 🟡 | <a href="#">MoiraiAgent (code)</a>         | Salesforce AI Research                      | No         | Yes              | 0.689 | 11.247    |
| 🟡 | <a href="#">Credence (code)</a>            | ContinualIST                                | No         | Yes              | 0.691 | 11.381    |
| 🟢 | <a href="#">Chronos-2 (code)</a>           | AWS   | No         | Yes              | 0.698 | 14.639    |
| 🔴 | <a href="#">TimesFM-2.5 (code)</a>         | Google Research                             | No         | Yes              | 0.705 | 17.588    |
| 🟡 | <a href="#">TimeCopilot (code)</a>         |   | No         | Yes              | 0.705 | 13.711    |
| 🔴 | <a href="#">PatchTST-FM-r1 (code)</a>      | IBM TSFM & Rensselaer Polytechnic Institute | Yes        | Yes              | 0.707 | 17.237    |
| 🔴 | <a href="#">TiRex (code)</a>               | NXAI  | No         | Yes              | 0.716 | 18.732    |
| 🔴 | <a href="#">Chronos-2-Synth (code)</a>     | AWS   | No         | Yes              | 0.720 |           |

# Klassische Zeitreihenmethoden im Nachteil

|        |                | MODEL2    |       |             |          |            |              |           |              |                |           |           |         |                |       |       |
|--------|----------------|-----------|-------|-------------|----------|------------|--------------|-----------|--------------|----------------|-----------|-----------|---------|----------------|-------|-------|
|        |                | Chronos-2 | TiRex | TimesFM-2.5 | Toto-1.0 | Moirai-2.0 | Chronos-Bolt | TabPFN-TS | Sundial-Base | Stat. Ensemble | AutoARIMA | AutoTheta | AutoETS | Seasonal Naive | Naive | Drift |
| MODEL1 | Chronos-2      | 50.0      | 72.0  | 71.0        | 74.0     | 92.0       | 94.0         | 85.0      | 91.0         | 86.0           | 95.0      | 94.0      | 89.0    | 98.0           | 98.0  | 94.0  |
|        | TiRex          | 28.0      | 50.0  | 48.5        | 61.5     | 76.5       | 76.5         | 69.0      | 80.5         | 81.0           | 90.0      | 94.0      | 84.0    | 97.0           | 96.0  | 94.0  |
|        | TimesFM-2.5    | 29.0      | 51.5  | 50.0        | 57.0     | 71.0       | 71.0         | 67.0      | 80.5         | 79.0           | 87.0      | 90.0      | 84.0    | 96.0           | 96.0  | 92.0  |
|        | Toto-1.0       | 26.0      | 38.5  | 43.0        | 50.0     | 58.0       | 56.0         | 58.0      | 67.5         | 73.0           | 81.0      | 82.0      | 79.0    | 91.0           | 94.0  | 89.0  |
|        | Moirai-2.0     | 8.0       | 23.5  | 29.0        | 42.0     | 50.0       | 55.0         | 52.0      | 68.5         | 73.0           | 81.0      | 85.0      | 76.0    | 87.0           | 91.0  | 86.0  |
|        | Chronos-Bolt   | 6.0       | 23.5  | 29.0        | 44.0     | 45.0       | 50.0         | 52.0      | 60.5         | 70.0           | 84.0      | 86.0      | 77.0    | 90.0           | 94.0  | 90.0  |
|        | TabPFN-TS      | 15.0      | 31.0  | 33.0        | 42.0     | 48.0       | 48.0         | 50.0      | 53.0         | 64.5           | 75.0      | 75.0      | 72.0    | 91.0           | 87.0  | 87.0  |
|        | Sundial-Base   | 9.0       | 19.5  | 19.5        | 32.5     | 31.5       | 39.5         | 47.0      | 50.0         | 66.0           | 76.0      | 77.0      | 71.0    | 88.0           | 88.0  | 83.0  |
|        | Stat. Ensemble | 14.0      | 19.0  | 21.0        | 27.0     | 27.0       | 30.0         | 35.5      | 34.0         | 50.0           | 64.0      | 75.0      | 79.5    | 79.5           | 85.0  | 89.0  |
|        | AutoARIMA      | 5.0       | 10.0  | 13.0        | 19.0     | 19.0       | 16.0         | 25.0      | 24.0         | 36.0           | 50.0      | 55.0      | 59.5    | 75.0           | 77.0  | 80.0  |
|        | AutoTheta      | 6.0       | 6.0   | 10.0        | 18.0     | 15.0       | 14.0         | 25.0      | 23.0         | 25.0           | 45.0      | 50.0      | 59.0    | 78.0           | 83.0  | 82.0  |
|        | AutoETS        | 11.0      | 16.0  | 16.0        | 21.0     | 24.0       | 23.0         | 28.0      | 29.0         | 20.5           | 40.5      | 41.0      | 50.0    | 63.5           | 64.0  | 68.0  |
|        | Seasonal Naive | 2.0       | 3.0   | 4.0         | 9.0      | 13.0       | 10.0         | 9.0       | 12.0         | 20.5           | 25.0      | 22.0      | 36.5    | 50.0           | 57.5  | 70.0  |
|        | Naive          | 2.0       | 4.0   | 4.0         | 6.0      | 9.0        | 6.0          | 13.0      | 12.0         | 15.0           | 23.0      | 17.0      | 36.0    | 42.5           | 50.0  | 81.0  |
| Drift  | 6.0            | 6.0       | 8.0   | 11.0        | 14.0     | 10.0       | 13.0         | 17.0      | 11.0         | 20.0           | 18.0      | 32.0      | 30.0    | 19.0           | 50.0  |       |

1:1 Duell der Modelle

Prozentuale Gewinnrate

→ Genauere Prognosen durch ZSTF-Modelle

Beurteilung auf Basis des fev-bench Benchmarks

<https://huggingface.co/spaces/autogluon/fev-bench>

# Benchmark-Case



# Benchmark-Case: Echte Zeitreihen aus der Praxis

Day-ahead Lastprognose (kWh / 15min)

Regelmäßig neue Teillasten ohne Trainingsdaten

**Hier:** 9 Zeitreihen von Großverbrauchern/Verbrauchergruppen

Insg. 540 Perioden mit Vorhersagehorizont 48h (96\*2 Werte)

Modellkontext 7 Tage (96\*7 Werte)

Optional: historische Wetterprognosen & lokale Feiertage

Normalized Mean Average Error (NMAE)

Inferenz auf AWS g6.xlarge (1€/h) mit Nvidia L4 (Mittelklasse-GPU)



# Nur Open weights Modelle berücksichtigt

- Viele Modelle öffentlich verfügbar (Github/Huggingface)
  - Freie Lizenzen wie MIT oder Apache 2.0 :
    - Chronos, timesfm, TabPFN, Toto
  - non-commercial / research / fauxpen source :
    - Moirai / MoiraiAgent, PatchTST, TiRex
- closed APIs:
  - IBM Granite TSFM, TimeGPT, Google Credence
- Nicht öffentlich verfügbar
  - Synapse, TimeFound, TSMamba, Siemens GTT



# Modellauswahl-Funnel: Metrik als finales Kriterium

DETAILS

KRITERIUM

Gescheiterte Modelle

Paket/Repo auf HF/GH/Pypi |  
nicht nur API

Code- und Modelverfügbarkeit

permissive

Lizenz

Moirai, TiRex

Bugfrei u. Plots/Metriken reproduzierbar

Code-Reproduzierbarkeit

Toto, visionTS  
Timecopilot/TSorchestra

Benötigter Kontext/Horizont umsetzbar

Use-Case-Adaption

Tiny-time-mixers, TabPFN

Hinreichend schnell für Use-Case

Inferenz

Native LLMs

Auswahl bestes Modell

Metrik

# Die *Duellanten* im Überblick

## Zero-Shot Modelle

### Chronos-Bolt

#### Tiny

8M  
Amazon  
Dez. 24  
Time Patching

### Chronos-Bolt

#### Base

250M  
Amazon  
Dez. 24  
Time Patching

### Chronos 2

#### + Covariates

120M  
Amazon  
Okt. 25  
Time Patching + Group  
Attention

### Chronos 2

120M  
Amazon  
Okt. 25  
Time Patching

### TimesFM 2.5

200M  
Google  
Okt. 25  
Time Patching



## Benchmark Modelle

### XGBoost

Supervised ML Model  
Entscheidungsbaum-basiert  
2 Jahre Trainingsdaten inkl.  
Wetterprognosen  
Parameter tuning

### Seasonal-Naive

7 Tage Saisonalität  
Wert 7 Tage zuvor

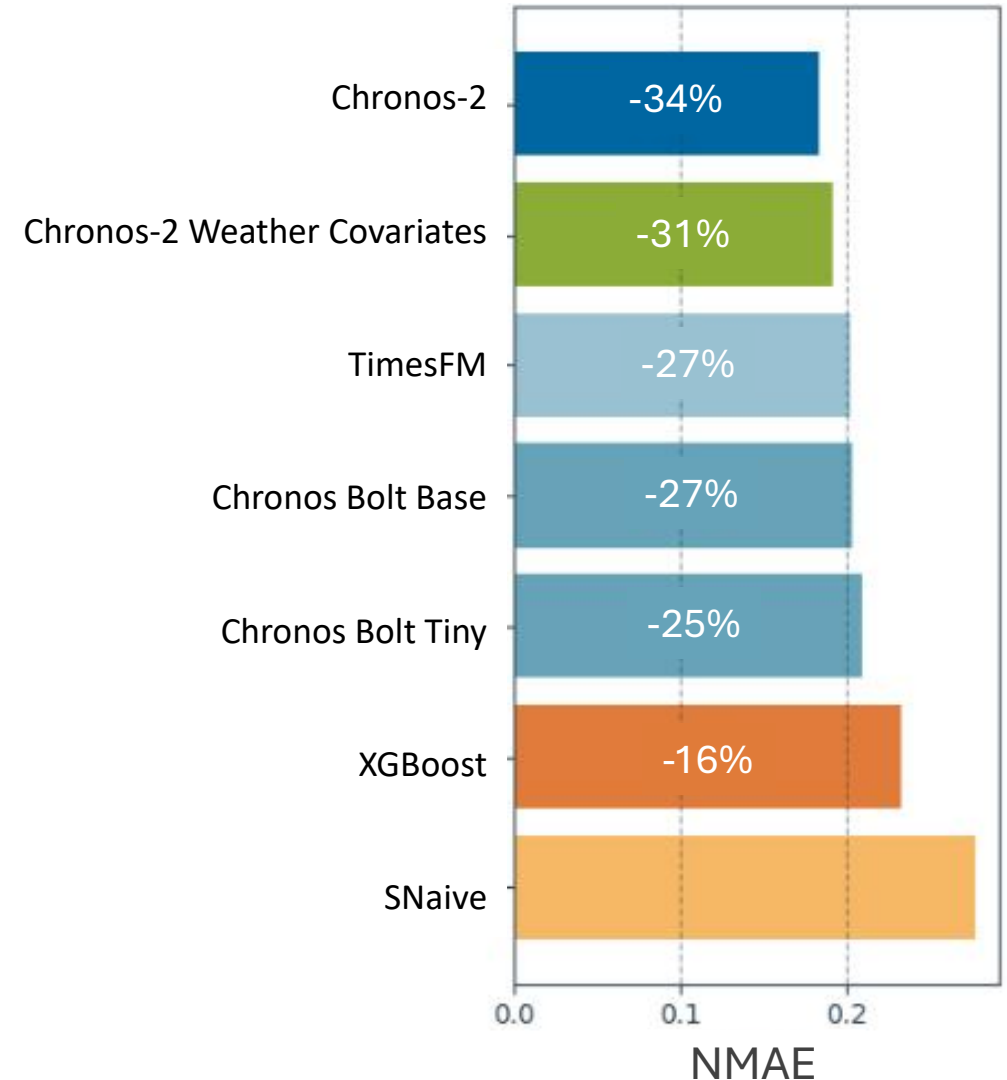
# Beste Prognosen mit Chronos 2

## Erkenntnisse:

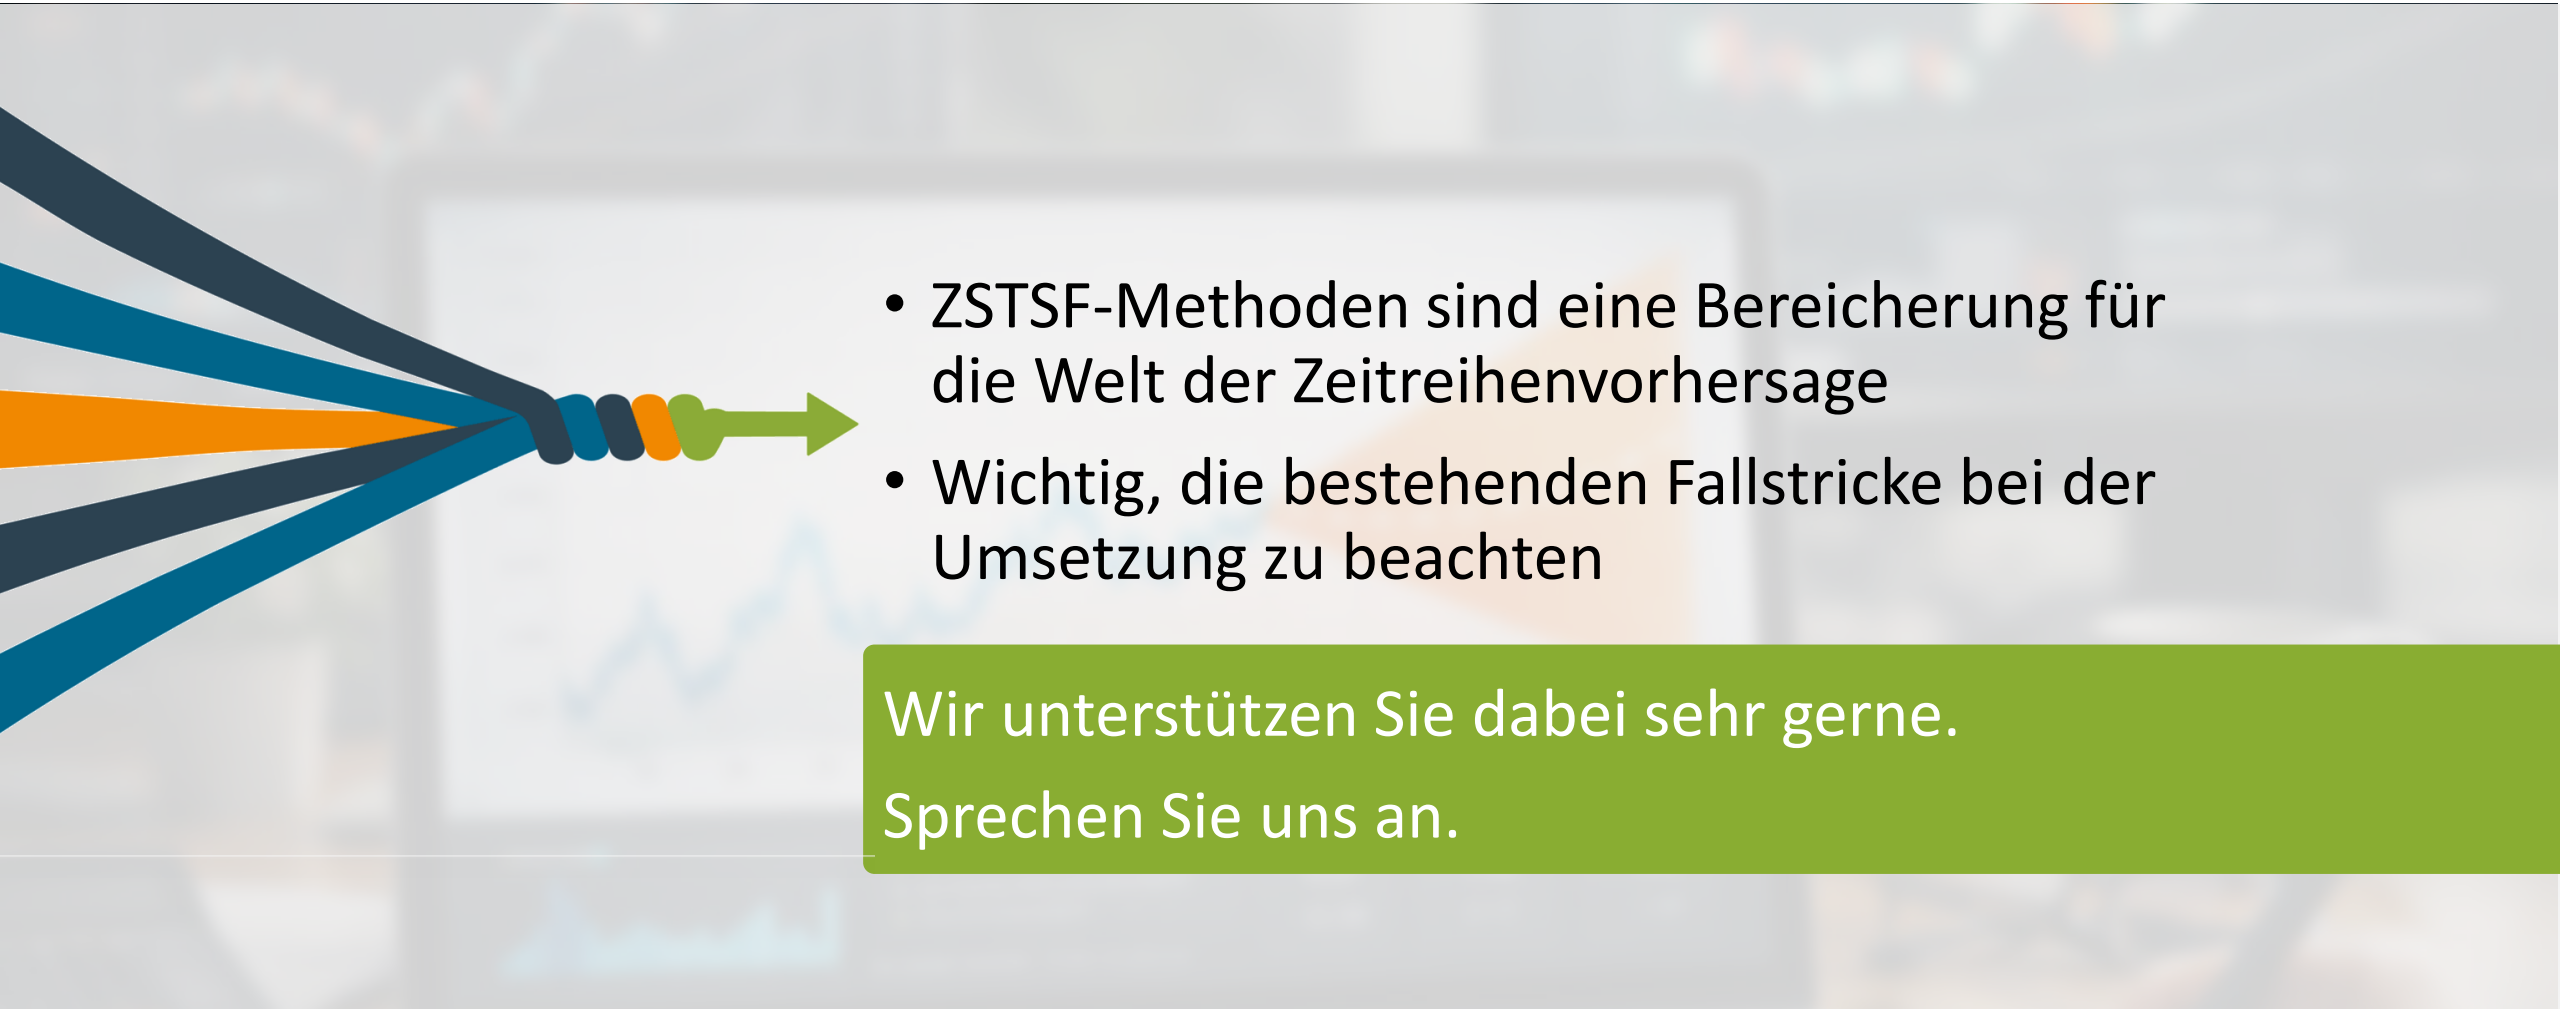
- Bestes Modell: Chronos 2
  - Bis zu 34% geringerer NMAE als Benchmark
  - Kein Vorteil durch Covariates
  - Inferenz in 0,5 Sek. GPU /44 Sek. CPU
- XGBoost nicht (mehr) konkurrenzfähig
  - ML-Training mit 2 Jahre Daten
  - CPU Latenz > Chronos 2

## Generalisierbarkeit?

- Mit eigenen Daten testen!



# Zusammenfassung

- 
- ZSTSF-Methoden sind eine Bereicherung für die Welt der Zeitreihenvorhersage
  - Wichtig, die bestehenden Fallstricke bei der Umsetzung zu beachten

Wir unterstützen Sie dabei sehr gerne.  
Sprechen Sie uns an.

# Ausblick: Unsere nächsten Online Sessions

## Data & AI Leadership

Was braucht die Führungskraft von heute für die digitalen Erfolgsgeschichten von morgen?

17. März 2026 | 11-12 Uhr



## Von der Idee zum Datenprodukt

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

21. April 2026 | 11-12 Uhr



**ONLINE  
SESSION**

Jetzt anmelden



Vielen Dank für Ihre Aufmerksamkeit

Q&A

*Let's Connect*  
**Matthias Henneke**  
Senior Data Scientist



E-Mail:  
[matthias.henneke@eoda.de](mailto:matthias.henneke@eoda.de)

