

# Entwicklung eines Machine-Learning basierten Up-Sampling Verfahrens für Windturbinen-Zeitreihen

Christian Fröhlich & Nergiz Küçükğacal

Graz, 12.02.2026



# Agenda

1. Motivation
2. Grundlagen
3. Methodik
4. Ergebnisse
5. Zusammenfassung & Ausblick

## Up-Sampling von Windturbinen-Zeitreihen

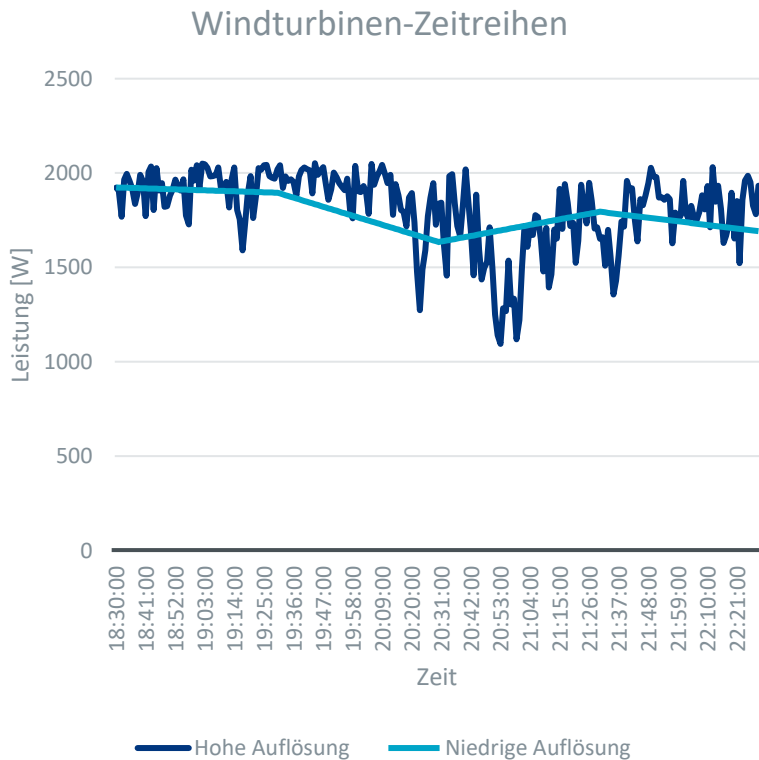


Abbildung: Vergleich hochauflösende und niedrigauflösende Windturbinenzeitreihen

- Simulative Abbildung von **Erneuerbaren Energien**
- **Volatiles Anlagenverhalten** bestimmt durch **Umwelteinflüsse**
- **Problemstellung:** Öffentlich zugängliche Zeitreihen oft mit geringer Auflösung (Wetterdaten)

### Status Quo\*

- Re-Analyse und dynamische Up-Sampling-Verfahren.
  - Komplexe Modelle & Hoher Datenaufwand
- Up-Sampling mit Wahrscheinlichkeitsdichtefunktionen
  - Geringere Genauigkeit
- Machine Learning Ansätze
  - Wenig erprobt im Anwendungsfall von Windturbinenzeitreihen

➤ **Fragestellung: Eigenen sich Machine Learning Ansätze zum Up-Sampling von Windturbinenzeitreihen?**


\*O. Omoyele *et al.*, "Increasing the resolution of solar and wind time series for energy system modeling: A review" *Renewable and Sustainable Energy Reviews*, vol. 189, p. 113792, Jan. 2024, doi: [10.1016/j.rser.2023.113792](https://doi.org/10.1016/j.rser.2023.113792).

# Machine Learning und Neuronale Netze

- **Definition** Machine Learning\*
  - Machine Learning ist die Wissenschaft (und Kunst), **Computer** so zu programmieren, dass sie **anhand von Daten lernen**.
- **Anwendungsbereich**
  - Anwendung, wo Probleme mit Hilfe von **Regeln** nur schwer oder **nicht gelöst werden können**

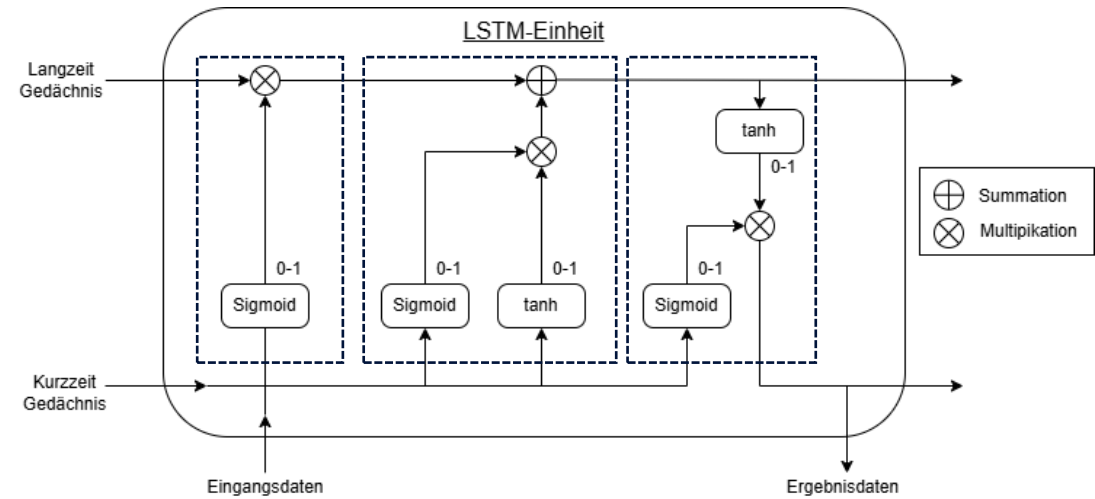
## Künstliche Neuronale Netzwerke

Graph bestehend aus Knoten und Kanten mit **Gewichtungen** und **Schwellen** (Aktivierungsfunktionen)



\*A. Géron, *Praxiseinstieg Machine Learning mit Scikit-Learn, Keras und TensorFlow: Konzepte, Tools und Techniken für intelligente Systeme*, 3., Aktualisierte und erweiterte Auflage. Heidelberg: O'Reilly, 2023.

## Long Short-Term Memory (LSTM-)Modell



- Gehört zur Gruppe der **Rekurrenten Neuronalen Netze**
- **Anwendungsfälle:** Verarbeitung von Sequenziellen Daten wie Zeitreihen, Texten etc.
- **Merkmale:** Forget Gate, Input Gate, Output Gate

# Fast Fourier Transformation

## Fourier Transformation

Integral-Transformation, welche Signale von dem Zeitbereich in den Frequenzbereich (Bildbereich) transformieren kann.

## Diskrete Fourier Transformation

Als effiziente Berechnungsmethode dient hier die **Fast Fourier Transformation**

- Diskrete Fourier Transformation:

$$\hat{a}_k = \sum_{n=0}^{N-1} e^{-2\pi j \cdot \frac{nk}{N}} \cdot a_n \text{ für } k = 0, \dots, N-1$$

- Inverse Diskrete Fourier Transformation

$$a_n = \frac{1}{N} \sum_{k=0}^{N-1} e^{2\pi j \cdot \frac{nk}{N}} \cdot \hat{a}_k \text{ für } n = 0, \dots, N-1$$

- Mit  $\hat{a}_k$  der **Fourier-Koeffizient** und  $a_j$  der **Messwert** aus der Zeitreihe.

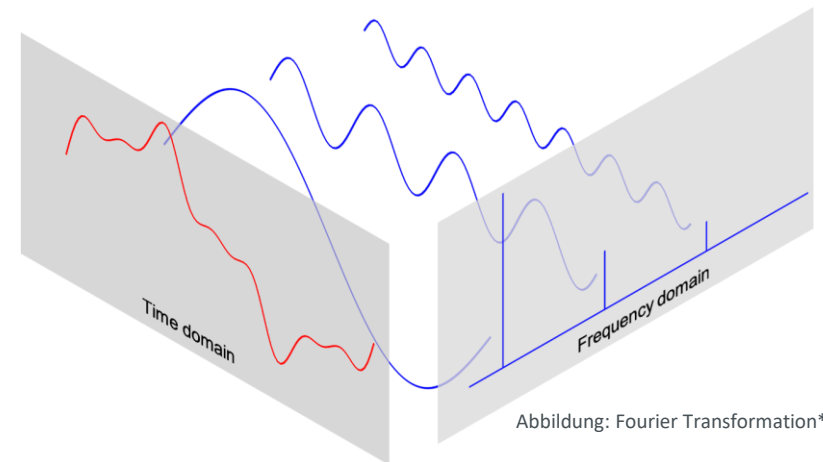


Abbildung: Fourier Transformation\*

\*<https://pythonnumericalmethods.studentorg.berkeley.edu/notebooks/chapter24.02-Discrete-Fourier-Transform.html>

# Modellanwendung: Zielbild unseres Modells

## Prozessbeschreibung

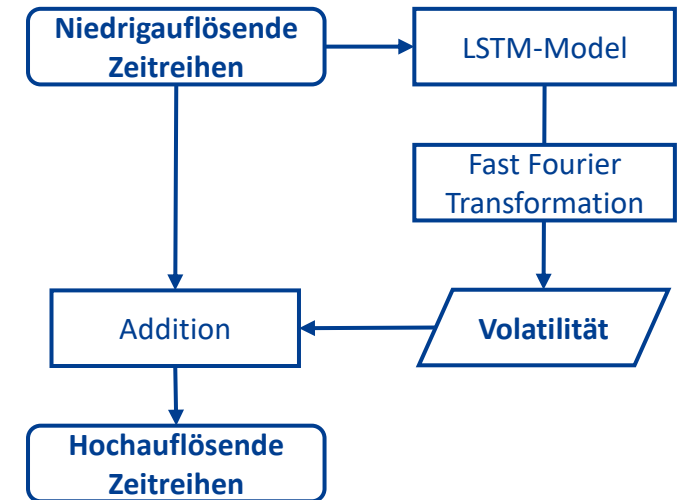
### 1. Eingangsdaten (Trend)

- Niedrigauflösende Windturbinenzeitreihen in stündlicher Auflösung
- Öffentlich zugängliche Datensätze (DWD, ERA5, etc.)

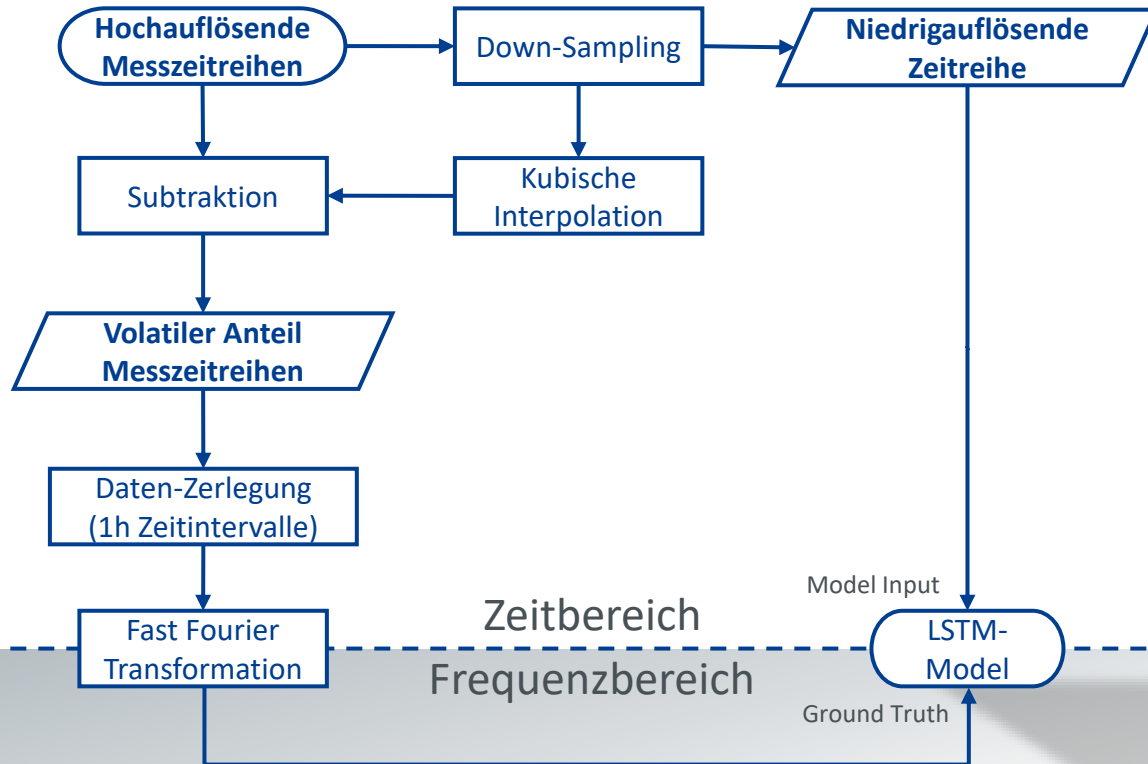
### 2. Volatilität bestimmen

- LSTM-Model bestimmt Volatilität auf Basis von Eingangsdaten

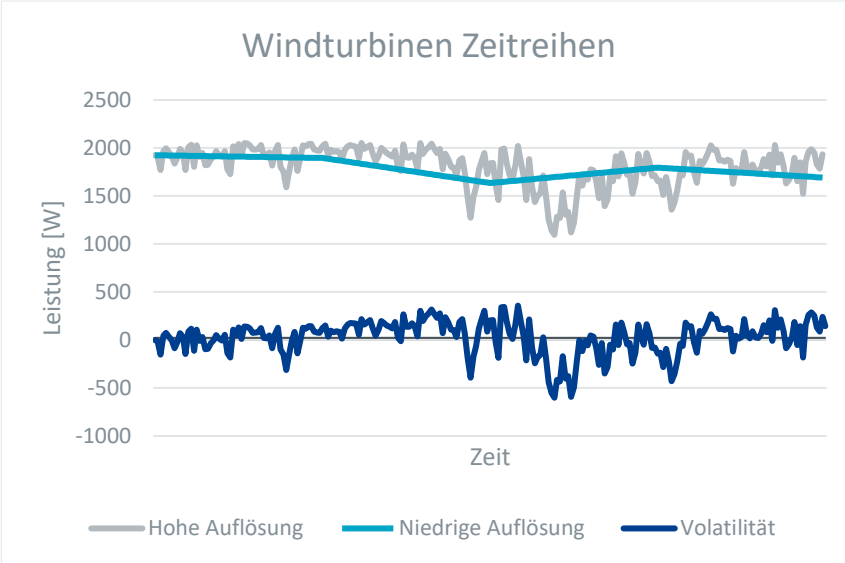
### 3. Hochauflösende Messzeitreihen durch Zusammensetzung von Trend und Volatilität



# Modeltraining



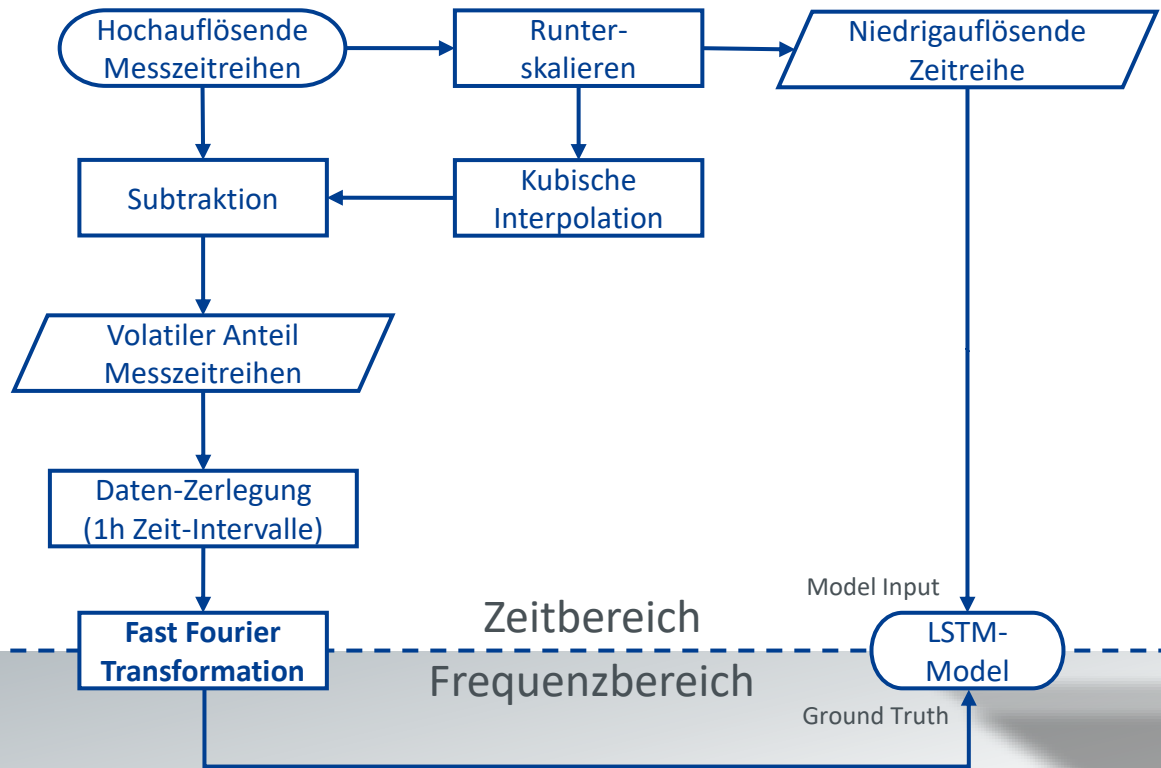
### Runterskalieren der Zeitreihe



- Bestimme auf Basis von Hochauflösender Zeitreihe\*:
  - ... Niedrigauflösende Zeitreihe (Trend)
  - ... Volatilität

\*Inspiriert von: Olauson, J., & Rydén, J. (2017). Simulating intra-hourly wind power fluctuations on a power system level. Wind Energy, 20(6), 973–985. <https://doi.org/10.1002/we.2074>

# Modeltraining



### Fast Fourier Transformation

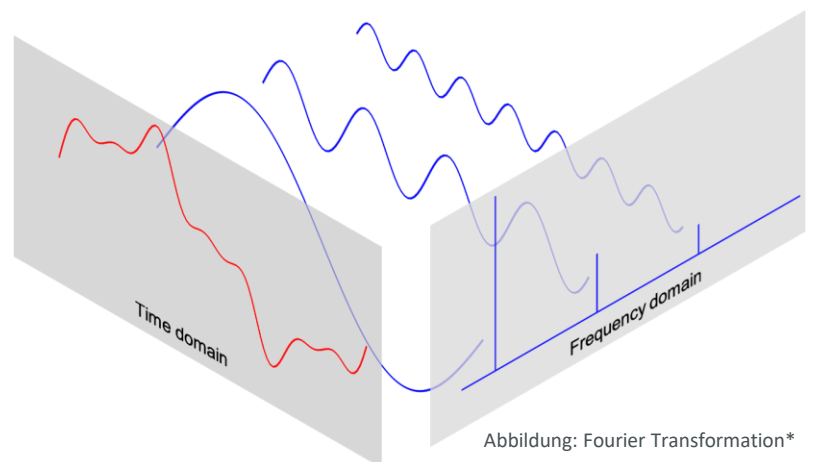


Abbildung: Fourier Transformation\*

- Zerlege **Volatilen Anteil** in seine **Frequenzcharakteristik\***

\*Inspiziert von: Olauson, J., & Rydén, J. (2017). Simulating intra-hourly wind power fluctuations on a power system level. Wind Energy, 20(6), 973–985. <https://doi.org/10.1002/we.2074>



## Eingangsdaten

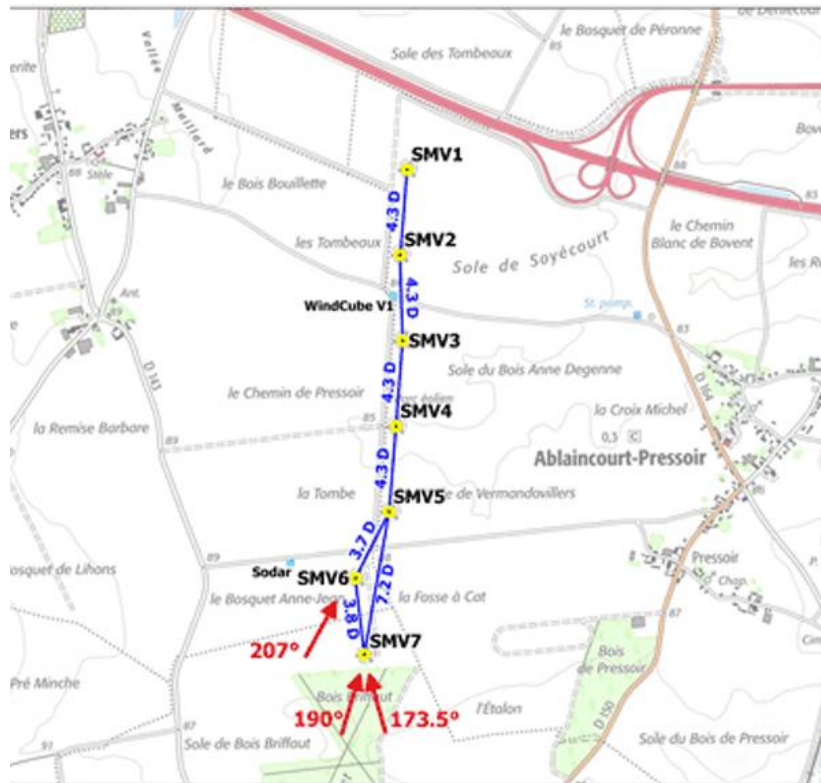


Abbildung: Geografische Standorte der Windturbinen \*

### Datensatz

Öffentliche Datensätze sind **selten und lokal begrenzt**, steigern aber die **Reproduzierbarkeit und Transparenz** der Modelle.


- minütliche Auflösung von 7 Turbinen
- Standort: zwischen Paris und Lille, im Norden Frankreichs
- Zeitraum: 28.02.2020 – 17.06-2021
- Messdaten: Wirkleistung, Temperatur, Windgeschwindigkeit, etc.

### Modellparametrierung

Feature Group	Hyperparameters
<ul style="list-style-type: none"> <li>• Active power</li> <li>• Wind speed</li> <li>• Temperature</li> <li>• (+ rolling mean)</li> </ul>	<ul style="list-style-type: none"> <li>• Input sequence: 4 hours</li> <li>• Number of layers: 2</li> <li>• Learning rate: 0.0005</li> <li>• Hidden dimension: 256</li> </ul>

\*Simley, E., et al. (2021). The Smarteole wind farm control dataset. Wind Energy Science, 6(5), 1427-1440. <https://doi.org/10.5194/wes-6-1427-2021>

# Bewertung



Name of Metric	R <sup>2</sup>	VSS
Value of Results	0.883	0.0162
Range of Value	max. 1	0 - 1
Ideal Result	1	1

- **Volatilität** wird durch das Modell abgebildet
- Der generelle **Trend** der Windturbine bleibt erhalten
- **Große Leistungsschwankungen** werden nicht abgebildet
- Fehlerhafte **Leistungssprünge** vorhanden

## Zusammenfassung

- **Zielsetzung:** Entwicklung eines Machine Learning Modells zum Up-Sampling von Windturbinenzeitreihen.
- **Status-Quo:**
  - Wenig Literatur zu Machine Learning Up-Sampling von Windturbinenzeitreihen
- Erfolgreiche **Entwicklung** eines Machine-Learning Ansatzes:
  - Abbildung Schwankungen
  - Trend der Anlage bleibt erhalten
- **Limitierungen** der Arbeit
  - Begrenzte öffentlich zugängliche Datensätze
  - Große Leistungsschwankungen werden nicht abgebildet
  - Fehlerhafte Leistungssprünge vorhanden

## Ausblick

- **Verbesserung des Modells**
  - Fehlerbehebung
  - Untersuchung weiterer Modelle (GAN, Diffusions Modelle)
  - Recherche weiterer/größerer Datensätze
- Weiterführende **Netzanalyse**
  - Abbildung von volatiler Leistungseinspeisung von Windturbinen in elektrischen Netzen
  - Untersuchung von Einfluss auf Spannungsqualität, Anlagenauslastung, Saisonalen Effekten, Wirtschaftlichkeit, etc.

# Herzlichen Dank

M. Sc. Christian Fröhlich


Forschung & Entwicklung  
Elektrische Netze  
FGH e. V.

[christian.froehlich@fgh-ma.de](mailto:christian.froehlich@fgh-ma.de)  
+49 15142018649




# Back-Up: Frequenz-basierte vs Zeit-basierte Methode

## Frequenz-basierte Methode



Name of Metric	R <sup>2</sup>	VSS
Value of Results	0.883	0.0162
Range of Value	max. 1	0 - 1
Ideal Result	<b>1</b>	<b>1</b>

## Zeit-basierte Methode



Name of Metric	R <sup>2</sup>	VSS
Value of Results	0.921	0.0005
Range of Value	max. 1	0 - 1
Ideal Result	<b>1</b>	<b>1</b>