

**Marta Sophia Potyka**

TU Dresden

Fakultät Elektrotechnik und Informationstechnik

Lehrstuhl für Elektroenergieversorgung

# Erstellung von Langzeitprognosemodellen industrieller, elektrischer Lastgänge mittels Kurzzeitmessung und Gauß'scher Prozesse

18. Symposium Energieinnovation // 14.-16.02.2024 // Graz

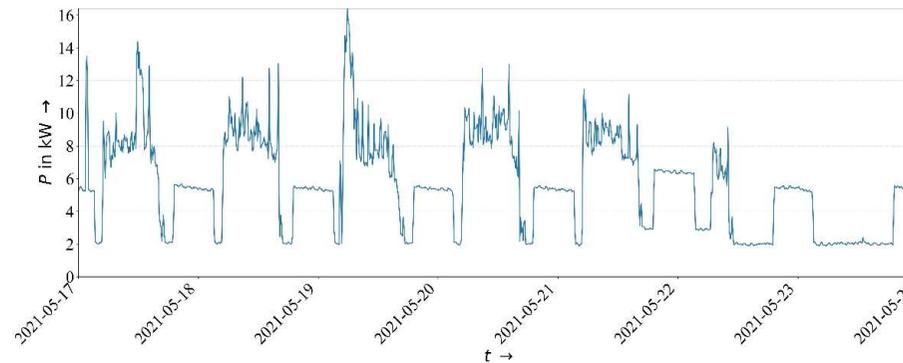
# Gliederung

1. Motivation
2. Stand der Technik
3. Methodik
4. Ergebnisse
5. Zusammenfassung und Ausblick

# Motivation

- Steigende Anforderungen an industrielle Unternehmen hinsichtlich effizienter (elektrischer) Energienutzung
- Zunehmender Einsatz von Energiemanagement
- Zumeist Hinzunahme von Messwerte einzelner technischer Anlagen und dem Übergabepunkt zum Energieversorger über ein Jahr
- Oft Fehlen dieser Messwerte

➔ **Langzeitprognosemodelle der elektrischen Wirkleistung aus Kurzzeitmessungen**



# Stand der Technik

Objekt	Spitzenwert	Ausgangsparameter	Größe Trainingsdatensatz	Größe Testdatensatz	Methode	Güte	Referenz
Haushalt	8 kW	Minütliche Leistung	2 Jahre	1 Tag	GP, ARMA	[18 %, 93 %] MAPE	[5]
Gebäude	800 kWh	Tägliche Energie	50 Tage	50 Tage	GP, SVM	≈9,5 % nMAE, ≈13,5 % nRMSE	[6]
Unternehmen	3,5 MW	Stündliche Wirkleistung	3 Jahre	1 Jahr	Curve-Fitting mit Fourier-Reihe	≈8,9 % MAPE	[7]
Ferienanlage	350 kW	Stündliche Wirkleistung	32 Tage	8 Tage	KNN kNN	≈8,9 %, ≈9,2 % MAPE	[8]
Unternehmen	< 120 kW	Substündliche Wirkleistung	< 4 Wochen	1 Jahr	GP	≈30 % MAPE, nRMSE	Diese Veröffentlichung

GP: Gauß'sche Prozesse  
 ARMA: Auto-Regressive Moving Average  
 SVM: Support Vector Machine  
 KNN: Künstliche Neuronale Netze

kNN: k-Nearest Neighbor  
 MAPE: Mean Absolute Percentage Error  
 nMAE: normalized Mean Absolute Error  
 nRMSE: normalized Root Mean Square Error

# Methodik

## Datensätze

Datensatz	Standort	Zeitliche Auflösung	Zeitraum	Grundlast	Spitzenlast
Autohaus	Hoyerswerda (Sachsen)	10 Minuten	01.05.2021 – 30.04.2022	2 – 2,5 kW	35 kW
Werkstatt	Hoyerswerda (Sachsen)	10 Minuten	01.04.2021 – 31.03.2022	8 – 10 kW (Sommer) 10 – 20 kW (Winter)	111 kW
Bäckerei	Bei Müncheberg (Brandenburg)	15 Minuten	01.01.2018 – 31.12.2018	2 – 3 kW	41 kW

# Methodik

## Trainings-, Validierungs-, Testdatensätze

Messung	Trainingsdatensatz	Validierungsdatensatz	Testdatensatz
16.09. – 14.10.	3 Wochen von der Messung	1 Woche von der Messung	1 Jahr
07.01. – 21.01. und 07.07. – 21.07.	Je 1 Woche von den Messungen	Je 1 Woche von den Messungen	1 Jahr

# Methodik

## Eingangsparameter

- Wetterdaten vom Deutschen Wetterdienst
- Zeitdaten aus dem Zeitstempel selbst generiert
- Varianten: nur Wetter-, nur Zeit- und Wetter- und Zeitparameter
- Auswahl durch Rastersuche und Korrelationsanalyse

Wetterparameter	Zeitparameter
Außentemperatur auf 2 m Höhe [°C]	Stunde [h] [0, 1, ... 23]
Relative Feuchtigkeit auf 2 m Höhe [%]	Minute des Tages [min] [0, 10, ..., 1430]
Niederschlagsdauer [min] [0 ... 60]	Wochentag [-] [0=Montag, ..., 6=Sonntag]
Mittlere Windgeschwindigkeit [m/s]	Feiertag [-] [Wahr oder Falsch]
Taupunkt auf 2 m Höhe [°C]	
Globalstrahlung [J/cm <sup>2</sup> ]	
Sonnenscheindauer [h] [0 ... 1]	

# Methodik

## Datenvorverarbeitung

- Bereinigung doppelter und fehlender Zeitstempel und Leistungswerte
- Untere Grenze: 0 kW
- Zur Erhöhung der Prognosegüte Clustern in Tyleistungsverläufe mittels k-Means-Algorithmus

Autohaus	Werkstatt	Bäckerei
Arbeitsleistungsverlauf	Arbeitsleistungsverlauf	Arbeitsleistungsverlauf
Basisleistungsverlauf	Basisleistungsverlauf	
Nachleistungsverlauf		

# Methodik

## Gauß'sche Prozesse

- Stochastischer Prozess mit Gauß'scher Verteilung
- Gauß'sche Verteilung: Normalverteilung mit Mittelwert  $\mu = 0$
- Daten jedoch selten in dieser Wahrscheinlichkeitsverteilung
- Als Approximation: Markov-Chain-Monte-Carlo-, speziell Hamiltonsche Monte-Carlo-Algorithmus
  
- Bestimmung der Kovarianzfunktion, auch Kernel genannt, elementar für Gauß'sche Prozesse
- Nutzung sogenannter Basiskernel beispielsweise von GPFlow
- Kombination der Basiskernel durch Addition oder Multiplikation zur Generierung neuer Kernel
- Rastersuche nach bester Kernelkombination anhand der Prognosegüte
  
- Bestimmung zusätzlich von Prior (Wahrscheinlichkeitsverteilung ohne Training) und Likelihood (Wahrscheinlichkeitsverteilung des Modells) mit Fitter-Methode von Python

# Methodik

## Gütekriterien

$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \left  \frac{P_{\text{progn } t} - P_{\text{wahr } t}}{P_{\text{wahr } t}} \right  \cdot 100 \%$	$\text{nMAE} = \frac{\frac{1}{n} \sum_{t=1}^n  P_{\text{progn } t} - P_{\text{wahr } t} }{P_{\text{max}}} \cdot 100 \%$
$\text{nRMSE} = \frac{\sqrt{\frac{1}{n} \sum_{t=1}^n (P_{\text{progn } t} - P_{\text{wahr } t})^2}}{P_{\text{mittel}}} \cdot 100 \%$	$r_E = 100 \% \cdot \left( \frac{E_{\text{progn}}}{E_{\text{wahr}}} - 1 \right)$

$t$ : Zeitschritt

$n$ : Gesamtanzahl von Zeitschritten

$P_{\text{progn } t}$ : Prognostizierte Leistung zu  $t$

$P_{\text{wahr } t}$ : Wirklich eingetretene Leistung zu  $t$

$P_{\text{max}}$ : Maximale Leistung des Datensatzes

$P_{\text{mittel}}$ : Durchschnittliche Leistung des Datensatzes

$E_{\text{progn}}$ : Prognostizierte Energie

$E_{\text{wahr}}$ : Wirklich eingetretene Energie

# Ergebnisse

## Einstellung der Gauß'schen Prozesse (1)

- Prior: Gamma-Verteilung
- Likelihood: Exponential-Verteilung

Typleistungsverlauf	Parameter	Wert für das Autohaus	Wert für die Werkstatt	Wert für die Bäckerei
Arbeitsleistungs- verlauf	Kernelkombination	RQ + Kos + WR	RQ + Kos + WR	RQ + Kos + WR
	$\sigma^2$	0,1	1,0	0,001
	$l$	100,0	100,0	100,0
	$\alpha$	0,00001	0,00001	0,001
	$\alpha_G$	0,1	0,1	2,0
	$\beta_G$	0,1	0,1	2,0

$\sigma^2$ : Varianz

$l$ : Länge

$\alpha$ : Skalenmix-Parameter

$\alpha_G$ : Hyperparameter 1 vom Prior

$\beta_G$ : Hyperparameter 2 vom Prior

RQ: Rational-Quadratischer Kernel

Kos: Kosinus Kernel

WR: Weißes-Rauschen Kernel

# Ergebnisse

## Einstellung der Gauß'schen Prozesse (2)

Typleistungsverlauf	Parameter	Wert für das Autohaus	Wert für die Werkstatt	Wert für die Bäckerei
Basisleistungs- verlauf	Kernelkombination	K + WR	RQ + Kos + WR	
	$\sigma^2$	0,1	0,01	
	$l$		1,0	
	$\alpha$		0,00001	
	$\alpha_G$	0,1	0,5	
	$\beta_G$	0,1	0,5	

K: Konstanter Kernel

# Ergebnisse

## Einstellung der Gauß'schen Prozesse (3)

Typleistungsverlauf	Parameter	Wert für das Autohaus	Wert für die Werkstatt	Wert für die Bäckerei
Nachleistungs- verlauf	Kernelkombination	K + WR		
	$\sigma^2$	0,1		
	$l$			
	$\alpha$			
	$\alpha_G$	0,1		
	$\beta_G$	0,1		

# Ergebnisse

## Einstellung der Gauß'schen Prozesse (4)

➤ Gleichungen der verwendeten Kernel:

$RQ(\mathbf{X}, \mathbf{X}') = \left(1 + \frac{(\mathbf{X} - \mathbf{X}')^2}{2\alpha l^2}\right)^{-\alpha}$	$Kos(\mathbf{X}, \mathbf{X}') = \sigma^2 \cos\left(2\pi \frac{(\mathbf{X} - \mathbf{X}')}{l}\right)$
$K(\mathbf{X}, \mathbf{X}') = \text{const.}$	$WR(\mathbf{X}, \mathbf{X}') = \delta(\mathbf{X} - \mathbf{X}')$

$\mathbf{X}$ : Trainingsdaten

$\mathbf{X}'$ : Testdaten

$\delta$ : Dirac-Impuls

# Ergebnisse

## Prognosegüte (1)

➤ Ergebnisse für das Autohaus:

Trainings- und Validierungsdatensatz	Eingangsparameter	MAPE (%)	nMAE (%)	nRMSE (%)	$r_E$ (%)
16.09. – 14.10.	Zeit	36,1	8,0	41,3	-12,0
	Wetter	37,8	7,0	37,6	-7,3
	Zeit und Wetter	31,2	6,1	33,3	-8,4
07.01. – 21.01. und 07.07. – 21.07.	Zeit	30,5	5,8	32,0	2,0
	Wetter	36,2	6,5	35,9	1,2
	Zeit und Wetter	30,6	5,7	30,9	1,2

# Ergebnisse

## Prognosegüte (2)

➤ Ergebnisse für das Autohaus:

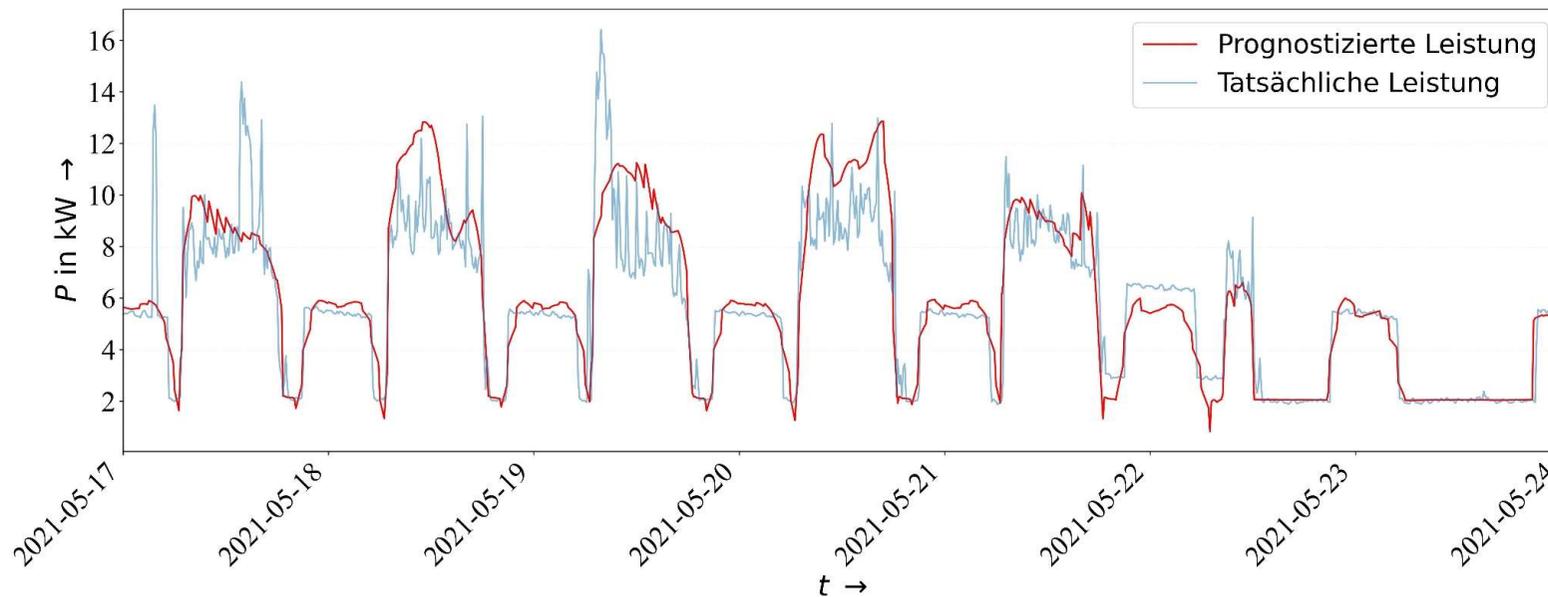


Bild 1: Lastgang vom Autohaus über eine Beispielwoche mit prognostiziertem und tatsächlichem Leistungsverlauf der Prognosevariante mit der geteilten Messung und nur Zeitparametern.

# Ergebnisse

## Prognosegüte (3)

➤ Ergebnisse für die Werkstatt:

Trainings- und Validierungsdatensatz	Eingangsparameter	MAPE (%)	nMAE (%)	nRMSE (%)	$r_E$ (%)
16.09. – 14.10.	Zeit	40,6	10,3	48,6	-35,1
	Wetter	49,9	11,9	56,6	-37,2
	Zeit und Wetter	40,4	10,3	48,9	-36,1
07.01. – 21.01. und	Zeit	54,9	6,2	29,9	14,1
	Wetter	66,1	7,6	36,4	14,9
07.07. – 21.07.	Zeit und Wetter	59,5	6,6	31,2	16,6

# Ergebnisse

## Prognosegüte (4)

### ➤ Ergebnisse für die Werkstatt:

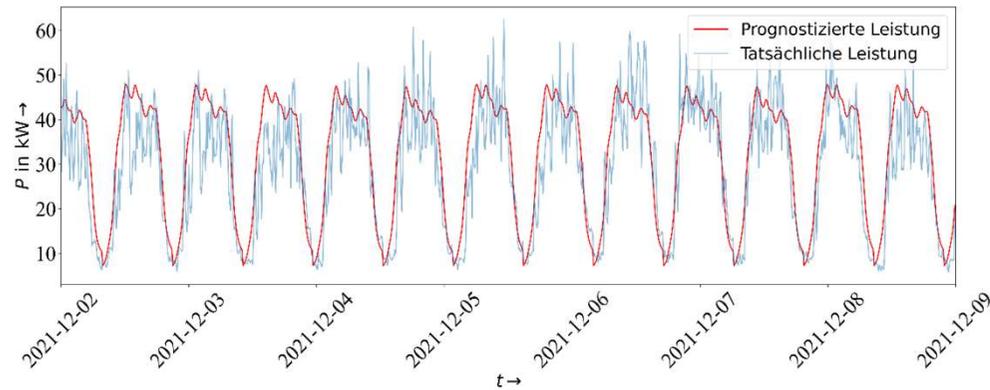
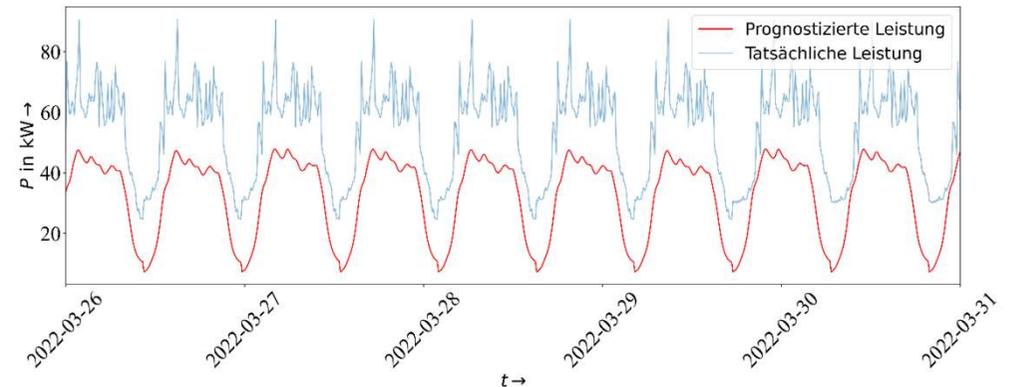


Bild 3: Lastgang von der Werkstatt über eine Beispielwoche 2 mit prognostiziertem und tatsächlichem Leistungsverlauf der Prognosevariante mit der ununterbrochenen Messung und nur Zeitparametern.

Bild 2: Lastgang von der Werkstatt über eine Beispielwoche 1 mit prognostiziertem und tatsächlichem Leistungsverlauf der Prognosevariante mit der ununterbrochenen Messung und nur Zeitparametern.



# Ergebnisse

## Prognosegüte (5)

➤ Ergebnisse für die Bäckerei:

Trainings- und Validierungsdatensatz	Eingangsparameter	MAPE (%)	nMAE (%)	nRMSE (%)	$r_E$ (%)
16.09. – 14.10.	Zeit	34,8	7,1	26,7	5,6
	Wetter	57,3	11,5	42,3	1,9
	Zeit und Wetter	40,8	8,1	30,4	5,0
07.01. – 21.01. und 07.07. – 21.07.	Zeit	30,0	6,8	26,7	-1,3
	Wetter	51,6	11,2	41,7	-4,4
	Zeit und Wetter	37,1	8,1	30,7	-0,4

# Ergebnisse

## Prognosegüte (6)

➤ Ergebnisse für die Bäckerei:

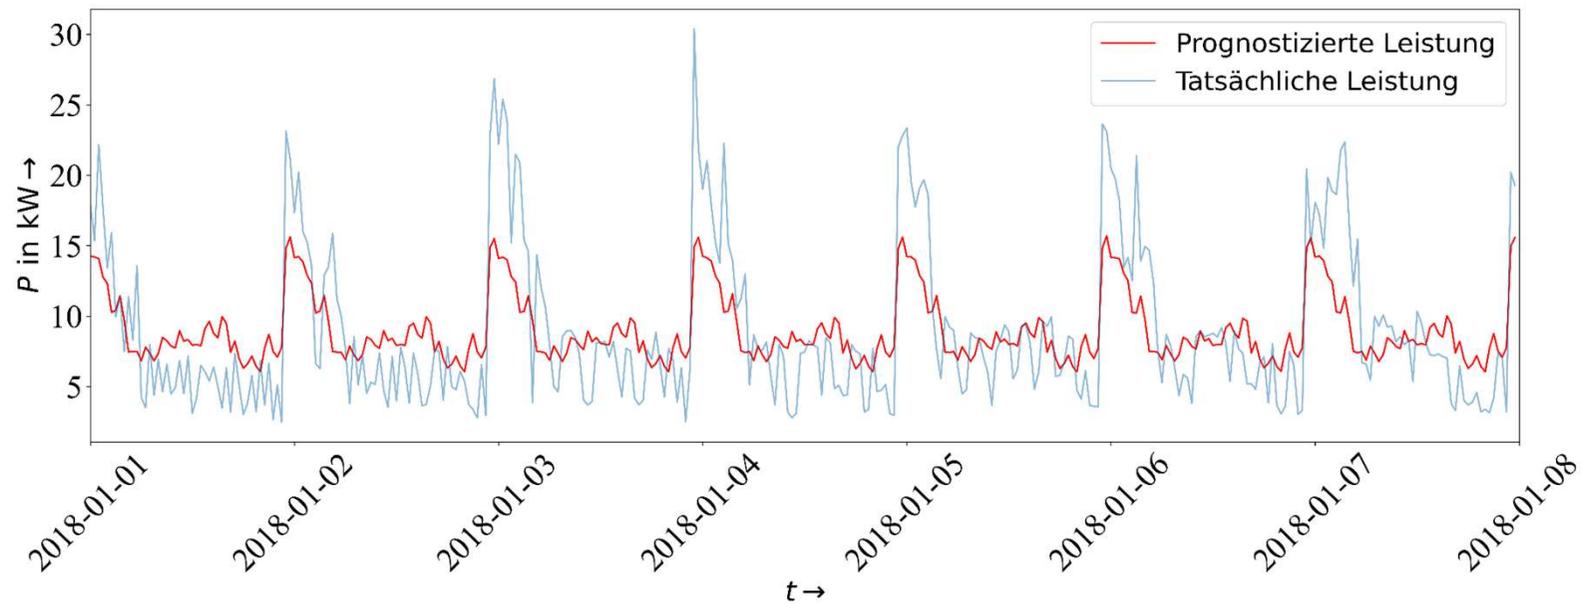


Bild 4: Lastgang von der Bäckerei über eine Beispielwoche mit prognostiziertem und tatsächlichem Leistungsverlauf der Prognosevariante mit der Messung und nur Zeitparametern.

# Zusammenfassung und Ausblick

## Zusammenfassung

- Erfolgreiche Aufstellung der Langzeitprognosemodelle
- Für 2 von 3 Datensätze Einhaltung der Sollwerte
- Höchste Prognosegüten mit alleiniger Verwendung von Zeit- als Eingangsparametern und bei 2 von 3 Datensätzen mit der geteilten Messung

## Ausblick

- Verbesserung der Prognosemodelle durch beispielsweise Änderung der Zeiträume des Trainings- und Validierungsdatensatzes oder Erstellen eigener Kernel für die Gauß'schen Prozesse
- Untersuchung weiterer Datensätze für breitere Anwendungsmöglichkeiten

# Literaturverzeichnis

- [1] H. Hilse, Interview am 21.11.2023 mit dem Geschäftsführer der GICON - Großmann Ingenieur Consult GmbH.
- [2] C. Kuster, Y. Rezgui, M. Mourshed: Electricity and power forecasting models: a critical systematic review, Sustainable Cities and Society (2017).
- [3] R. Patel, M. Patel, R. Patel: A review: introduction and understanding of load forecasting, Journal of Applied Science and Computations (2019).
- [4] S. P. V. Gupta: An overview of different types of load forecasting methods and the factors affecting the load forecasting, International Journal for Research in Applied Science and Engineering (2017).
- [5] M. Alamaniotis, L. H. Tsoukalas: Anticipation of minutes-ahead household active power consumption using Gaussian processes, 6th International Conference on Information, Intelligence, Systems and Applications (2015).
- [6] B. Han, S. Zhang, L. Qin, X. Liu, Y. Wangand, Z. Li: Comparison of Support Vector Machine, Gaussian Process Regression and Decision Tree Models for Energy Consumption Prediction of Campus Buildings, 8th International Conference on Hydraulic and Civil Engineering: Deep Space Intelligent Development and Utilization Forum (2022).
- [7] Ü. B. Filik, Ü. N. Gerek, M. Kurban: Hourly Forecasting of Long Term Electric Energy Demand Using a Novel Modeling Approach, Fourth International Conference on Innovative Computing, Information and Control (2009).
- [8] N. J. Johannesen, M. L. Kolhe, M. Goodwin: Load Demand Analysis of Nordic Rural Area with Holiday Resorts for Network Capacity Planning, 4th International Conference on Smart and Sustainable Technologies (2019).
- [9] [https://www.dwd.de/DE/klimaumwelt/cdc/cdc\\_node.html](https://www.dwd.de/DE/klimaumwelt/cdc/cdc_node.html), abgerufen am 04.01.2024
- [10] <https://scikit-learn.org/stable/modules/generated/sklearn.cluster.KMeans.html>, abgerufen am 04.01.2024.
- [11] <https://www.gpflow.org/>, abgerufen am 04.01.2024.
- [12] D. K. Duvenaud: Automatic Model Construction with Gaussian Processes, University of Cambridge (2014).
- [13] C. E. Rasmussen und C. K. I. Williams, "Gaussian Processes for Machine Learning", the MIT Press, 2006.
- [14] <https://fitter.readthedocs.io/>, abgerufen am 05.01.2024.

**Vielen Dank für Ihre Aufmerksamkeit**

