

H T
W E
G I

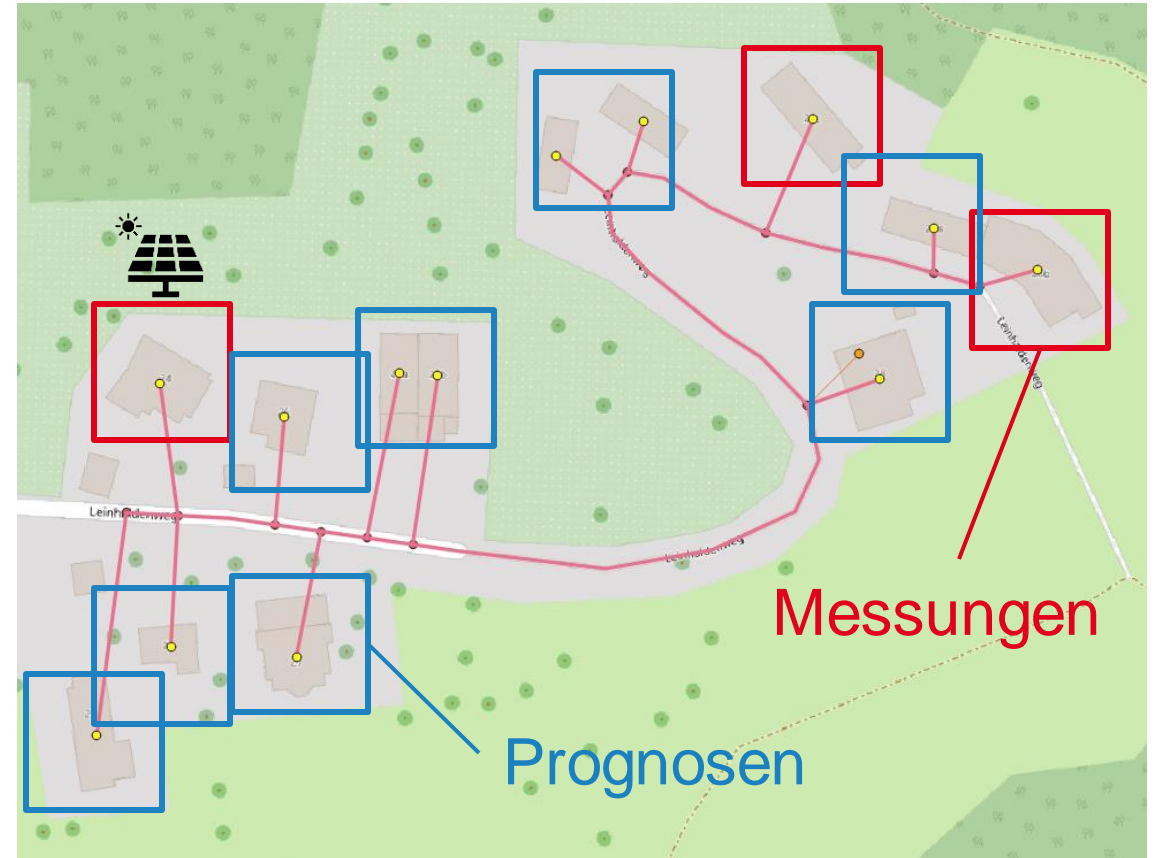
Hochschule Konstanz
Fakultät Elektrotechnik
und Informationstechnik

Probabilistische Lastprognosen mit Normalizing Flows

Marcel Arpogaus

Use-Case Betriebsführung

- Niederspannungsnetz nur unvollständig vermessen
- Für fehlende Messungen werden Prognosen benötigt



Warum keine Mittelwerte? Beispiel: Standardlastprofile




Abb. aus: [1] M. Anvari, E. Proedrou, B. Schaefer, C. Beck, H. Kantz, and M. Timme, "Data-Driven Load Profiles and the Dynamics of Residential Electric Power Consumption," arXiv:2009.09287 [physics], Sep. 2020, Accessed: Jan. 21, 2022. [Online]. Available: <http://arxiv.org/abs/2009.09287>

Generative KI Modelle

GPT-4 visual input example, École Polytechnique Exam Question:

User Answer question I.1.a. Think step-by-step.

I. Principe de la détection de rayonnement avec un bolomètre

Comme illustré sur la figure 1 un bolomètre est constitué d'un absorbeur qui reçoit le rayonnement que l'on désire détecter. Sa température T , supposée uniforme, est mesurée à l'aide d'un thermomètre incorporé, constitué d'un matériau conducteur dont la résistance $R(T)$ varie avec la température T ; cette variation est caractérisée par le coefficient $\alpha = \frac{1}{R} \frac{dR}{dT}$. L'ensemble possède la capacité thermique C_{th} .

Un barreau, conducteur thermique, homogène, de longueur L , de section S et de conductivité thermique λ et sans échanges thermiques latéraux, relie le bolomètre à un thermostat de température T_b fixe.




Figure 1 - Schéma d'un bolomètre

I.1. Dans cette première partie, on étudie le comportement du bolomètre en régime stationnaire, à la température de fonctionnement $T = T_b$.

I.1.a) Exprimez la température $T(x)$ en tout point du barreau conducteur repéré par son abscisse x ; on prendra $T(0) = T_b$ et $T(L) = T_b$.

GPT-4 To answer question I.1.a, we need to express the temperature $T(x)$ in every point of the conductive bar, which is characterized by the abscissa x . We are given that $T(0) = T_0$ and $T(L) = T_b$.

For a stationary regime, the heat equation for the one-dimensional heat conduction in the bar is:
$$d^2T/dx^2 = 0$$

Integrating once, we get:
$$dT/dx = C_1$$

Integrating a second time:
$$T(x) = C_1x + C_2$$

To determine the constants C_1 and C_2 , we use the boundary conditions:
 $T(0) = T_0$, which gives $C_2 = T_0$
 $T(L) = T_b$, which gives $C_1 = (T_b - T_0)/L$

Finally, the expression for $T(x)$ is:
$$T(x) = (T_b - T_0) * (x/L) + T_0$$


This represents a linear temperature profile along the conductive bar, with a slope of $(T_b - T_0)/L$.

Generative KI Modelle

“A Golden Retriever dog wearing a blue checkered beret and red dotted turtleneck.”




Gebäudetyp	Einfamilienhaus
Tag	14/08/2022
Uhrzeit	00:00
Zeitschritte	48
...	...




Linke Abb. aus: C. Saharia et al., “Photorealistic Text-to-Image Diffusion Models with Deep Language Understanding,” May 2022, doi: [10.48550/arXiv.2205.11487](https://doi.org/10.48550/arXiv.2205.11487)

Rechte Abb. aus: M. Arpogaus, M. Voss, B. Sick, M. Nigge-Urcher, und O. D. N., „Short-Term Density Forecasting of Low-Voltage Load using Bernstein-Polynomial Normalizing Flow s“, IEEE Trans. Smart Grid, S. 1–1, 2023, doi: [10.1109/TSG.2023.3254890](https://doi.org/10.1109/TSG.2023.3254890).


Wahrscheinlichkeitsdichte




Wahrscheinlichkeitsdichte



Wahrscheinlichkeitsdichte



Wie funktionieren Normalizing Flows?



Wie funktionieren Normalizing Flows?




Abb. aus: M. Arpogaus, "Probabilistic short-term load forecasting using conditioned normalizing flows," 2020.


Bernstein Normalizing Flows

Auswertung der Wahrscheinlichkeitsdichte

$$p_y(y|\mathbf{x}) = p_z(f(z, \theta_x)) |\det \nabla f(z, \theta_x)|$$

Generierung neuer Beispiele

$$y \sim p_y(y|\mathbf{x}) = f^{-1}(z, \theta_x) \text{ mit } z \sim p_z(z)$$



Probabilistische Lastprognosen mit Bernstein Normalizing Flows




Abb. aus: M. Arpogaus, M. Voss, B. Sick, M. Nigge-Uricher, und O. D. N., „Short-Term Density Forecasting of Low-Voltage Load using Bernstein-Polynomial Normalizing Flow s“, IEEE Trans. Smart Grid, S. 1–1, 2023, doi: [10.1109/TSG.2023.3254890](https://doi.org/10.1109/TSG.2023.3254890).

Evaluation der Robustheit

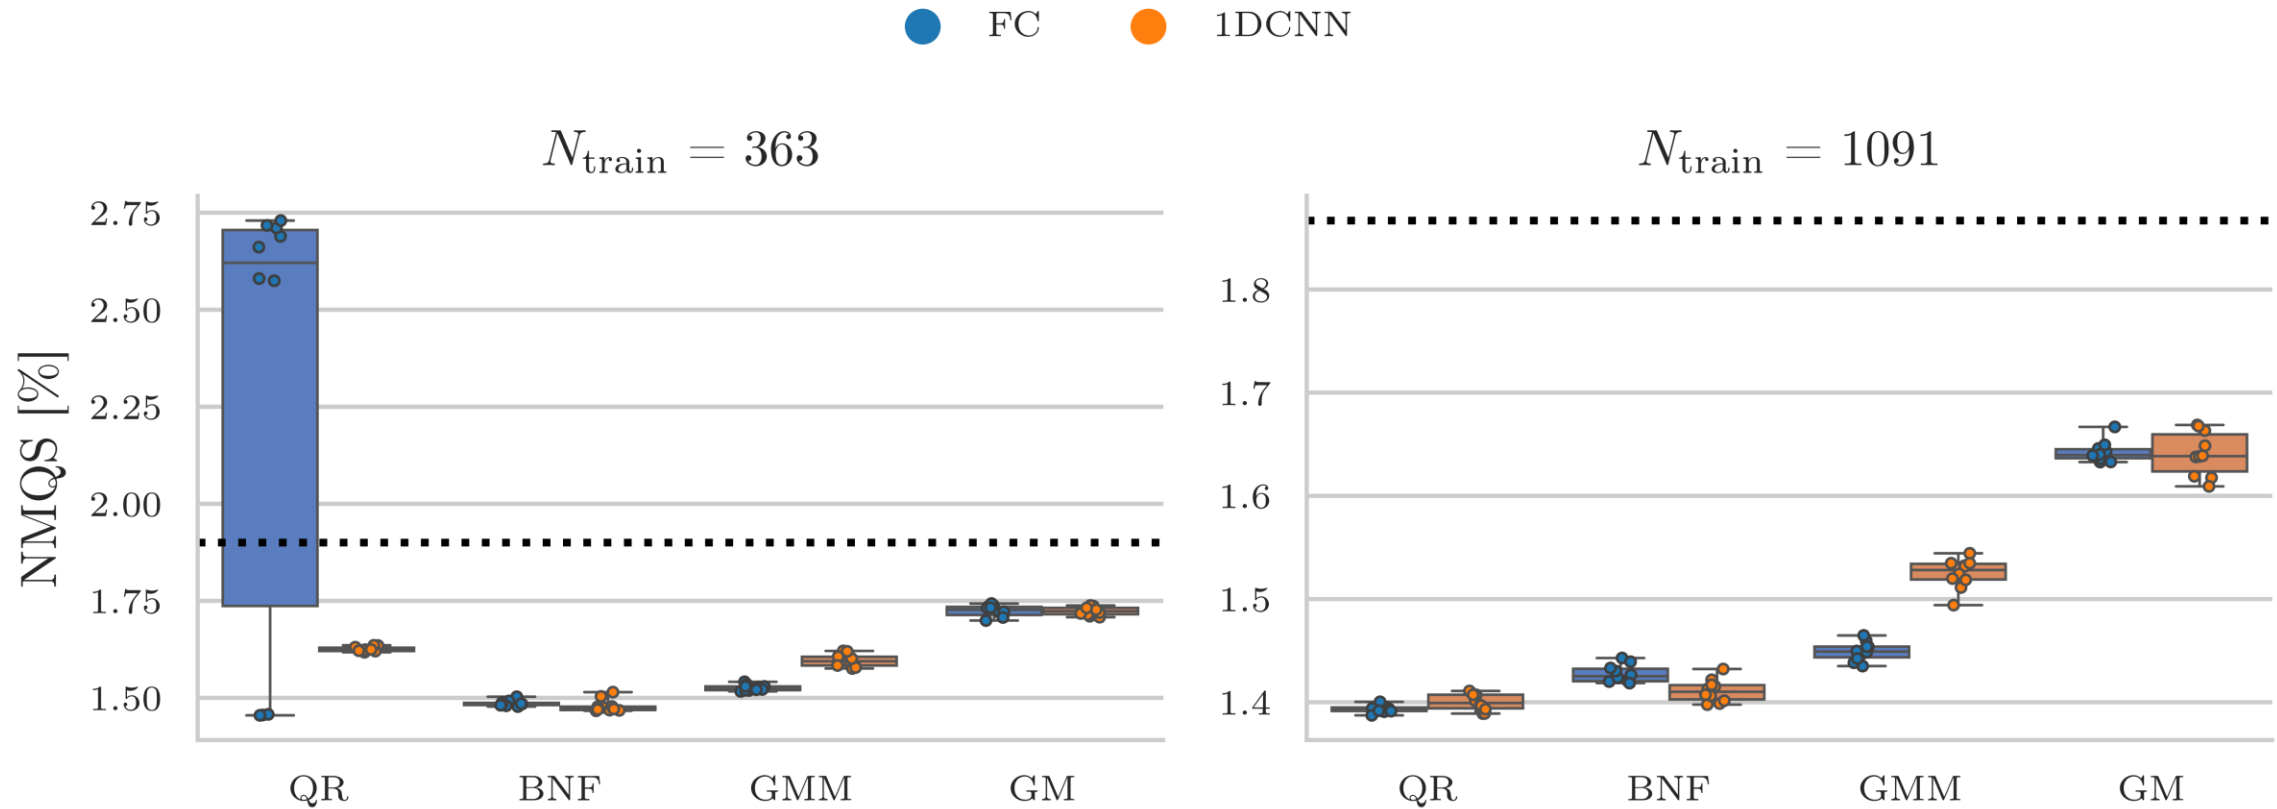


Abb. aus: M. Arpogaus, M. Voss, B. Sick, M. Nigge-Uricher, und O. D. N., „Short-Term Density Forecasting of Low -Voltage Load using Bernstein-Polynomial Normalizing Flow s“, IEEE Trans. Smart Grid, S. 1–1, 2023, doi: [10.1109/TSG.2023.3254890](https://doi.org/10.1109/TSG.2023.3254890).

QR: Qunatile Regression
 BNF: Bernstein Normalizing Flow
 GMM: Gaussian Mixture Model
 GM: Gaussian Model

Einfluss der Datenmenge auf die Vorhersagegenauigkeit

Evaluierungsergebnisse von Modellen, die mit einer unterschiedlichen Anzahl von Haushalte¹.

- Dargestellt sind die Ergebnisse von NMQS auf den drei verschiedenen Testsätzen zusammen mit dem Mittelwert.
- Die gestrichelte Linie stellt das Ergebnis der ECDF-Baseline dar.
- Niedriger ist besser.

Beobachtungen:


1. Die Leistung der Modelle scheint sich asymptotisch einem Grenzwert zu nähern.
2. Die Ergebnisse in den sehr datenarmen Konfigurationen unterscheiden sich stark

¹ $N_{\text{train}} \in \{36 (1\%), 181 (5\%), 363 (10\%), 727 (20\%), 1091 (30\%), 1455 (40\%), 1819 (50\%)\}$

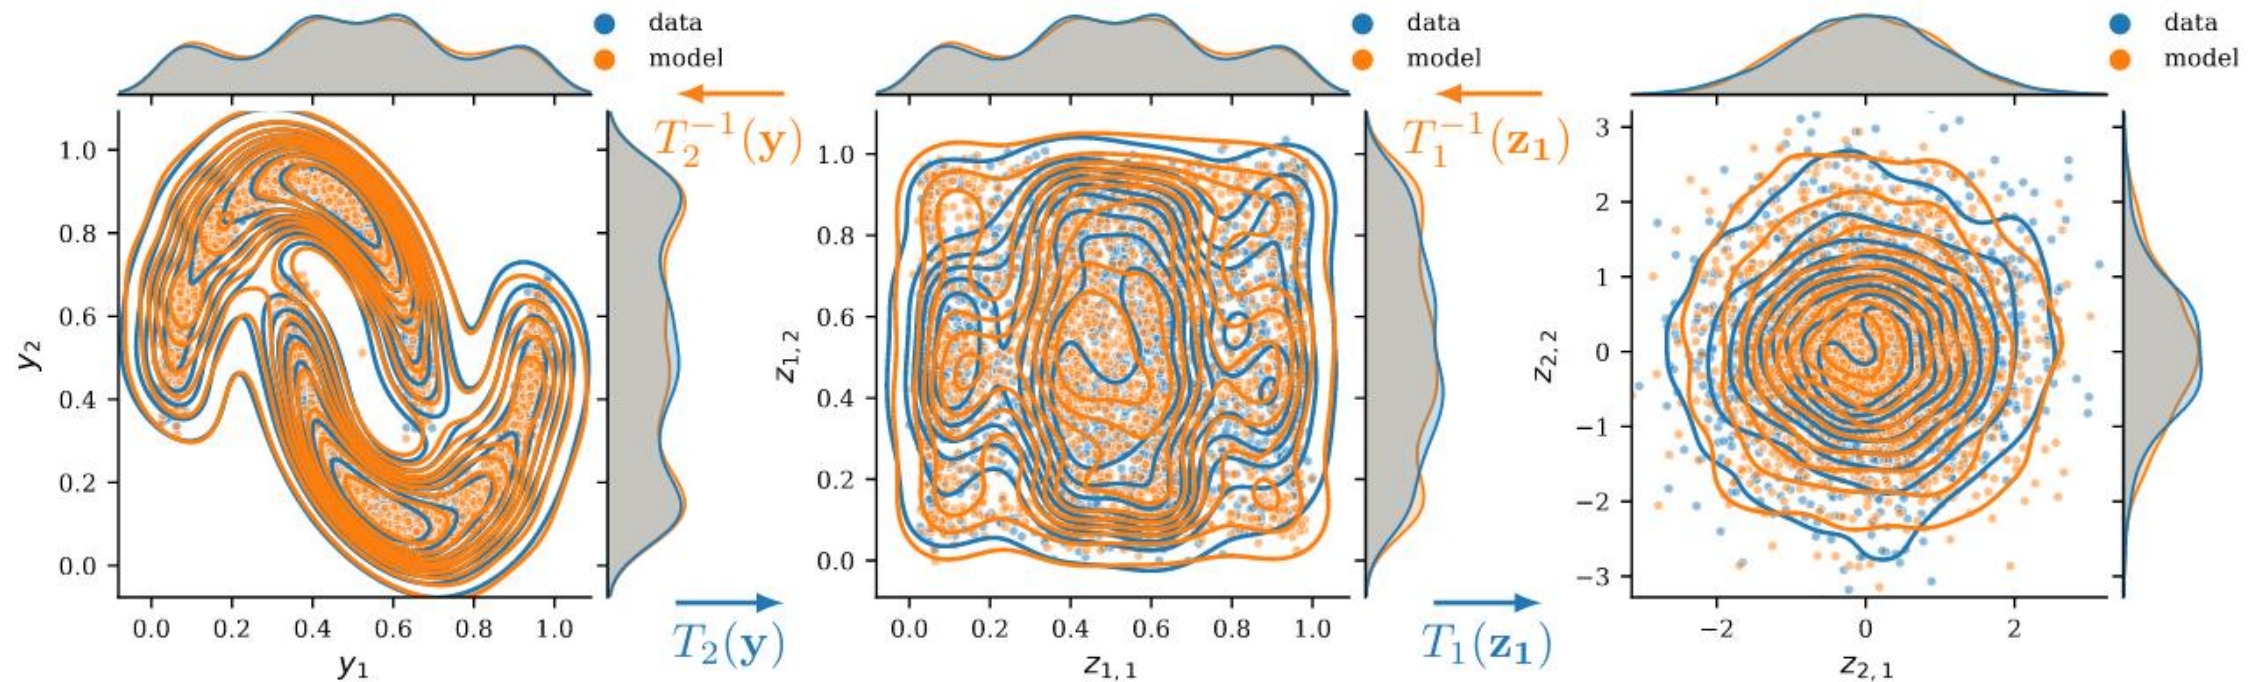
QR: Quantile Regression GMM: Gaussian Mixture Model

BNF: Bernstein Normalizing Flow GM: Gaussian Model


Abb. aus: M. Arpogaus, M. Voss, B. Sick, M. Nigge-Uricher, und O. D. N., „Short-Term Density Forecasting of Low-Voltage Load using Bernstein-Polynomial Normalizing Flow“, IEEE Trans. Smart Grid, S. 1–1, 2023, doi: [10.1109/TSG.2023.3254890](https://doi.org/10.1109/TSG.2023.3254890).




Ausblick: Erweiterung auf komplexe multivariate Verteilungen






Erste synthetische Lastzeitreihen



Erste synthetische Lastzeitreihen



Qualitative Beurteilung der Ergebnisse





Zusammenfassung

- Bernstein Normalizing Flows können **robust und interpretierbar** komplexe Verteilungen abbilden
- Dadurch lassen sich natürliche Schwankung und damit verbundene **Unsicherheiten abschätzen**
- Durch die Erweiterung als autoregressives Modell, lassen sich **realistische Zeitreihen** für beliebige Gebäude generieren
- Mögliche Anwendungen sind **Netzzustandsschätzung, Betriebsführung, Fehlererkennung** sowie **zeitreihen-gestützte Netzplanung**

Vielen Dank für die Aufmerksamkeit!

Gibt es Fragen?

 marcel.arpogaus@htwg-konstanz.de

 [/in/marpogaus](https://www.linkedin.com/in/marpogaus)

 [/marpogaus](https://github.com/marpogaus)

