

**HOCHSCHULE  
HANNOVER**  
UNIVERSITY OF  
APPLIED SCIENCES  
AND ARTS

–  
*Fakultät II*  
*Maschinenbau und*  
*Bioverfahrenstechnik*



GEFÖRDERT VOM



**Bundesministerium  
für Bildung  
und Forschung**

# **Vorhersage des Tagesgangs von Heizlasten**

*Dialogplattform Power to Heat*

Dipl.-Math.techn. Frithjof Fehsenfeld<sup>1</sup>, Prof. Dr.-Ing. Andreas Huck<sup>1</sup>,  
Prof. Dr.-Ing. Michael Kurrat<sup>2</sup>, Prof. Dr.-Ing. Paul Diersen<sup>1</sup>

<sup>1</sup>Hochschule Hannover, IVEK

<sup>2</sup>Technische Universität Braunschweig, elenia

06.05.2015



# Inhalt

1. Einleitung & Projektübersicht
2. Lastvorhersage
3. Daten
4. Ergebnisse
5. Zusammenfassung und Ausblick

# 1. Einleitung


- Simulationen werden häufig mit **perfektem Wissen** durchgeführt
- die Planung der Einsatzzeiten von Erzeugungseinheiten erfolgt aber mit **Prognosen**
- Anwendungsfälle: Regelenergiebereitstellung, Handel an der Strombörse
  
- Sind Prognosen möglich?
- Welche **Verfahren** bieten sich an?
- Welche **Daten** werden benötigt?
- Wie **zuverlässig** ist meine Prognose?

# 1. Projektübersicht Nevora

*Netzlastoptimierung durch vorausschauende Steuerung von BHKW und Wärmepumpen*


## **Ziele:**

- CO<sub>2</sub> Reduktion durch energieeffiziente Bereitstellung und Verteilung elektrischer Energie mittels
  - Entkopplung des Wärme- und Strombedarfs durch thermischen Speicher
  - Vorhersage des Lastgangs
  - netzorientierten Betrieb von BHKW und Wärmepumpen
  - Nutzung der Gebäudesubstanz als thermischen Pufferspeicher
- Erstellen eines Energiemanagementsystem zur Verwaltung und Steuerung



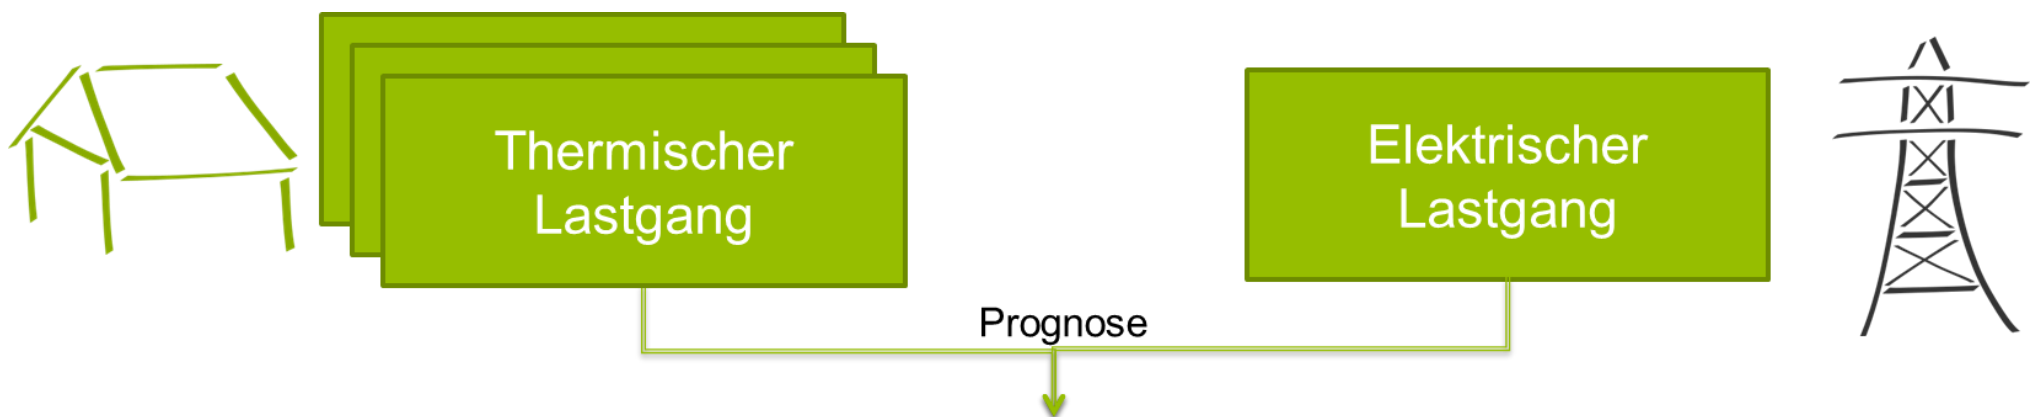
# 1. Projektübersicht

## Schema



# 2.1 Lastvorhersage für Wärme

- die kurzfristige Vorhersage von Lasten (Short-term load forecasting, STLF) deckt typischerweise den Bereich von 1h bis wenige Wochen in die Zukunft ab
- Heizlastprognosen sind deutlich weniger untersucht als Stromlastprognosen
  - Verfahren lassen sich übertragen
  - Einflussfaktoren sind ähnlich
- wesentlicher Unterschied: Trägheit




# 2.1.1 Verfahren zur Lastvorhersage

- Synthetische Lastprofilverfahren (z. B. nach VDI 4655)
- Vergleichstageverfahren
- Autoregressive Zeitreihenmodelle
- Kalman Filter

- Naive Prognose
- Maschinelles Lernen
  - künstliche neuronale Netze (KNN)
  - k-Nearest Neighbors
  - Support Vector Machines
  - Gradient Boosting

**bereits genutzte Verfahren**



Grundprinzip (fast) aller Verfahren: Anhand bekannter Messdaten wird ein mathematisches Modell für den Heizbedarf erstellt.

## 2.1.2 Gradient Boosting

*... warum?*

- landete bei der **Kaggle Global Energy Forecasting Competition 2012 (GECOM2012)** bei der Stromlastvorhersage zweimal in den Top 5 (von 105 Teilnehmern) (Taieb und Hyndman, 2014; Lloyd 2014)
- liefert vergleichbare Ergebnisse wie künstliche neuronale Netze
- **White-Box-Algorithmus:** Die Ergebnisse sind interpretierbar (Friedman, 1999).
- robustes Verfahren
- wenig Datenvorverarbeitung
- erlaubt die einfache Berechnung von Prognoseintervallen

### Nachteile

- extrapoliert weniger gut als andere Verfahren
- schwieriger zu parallelisieren – deswegen teilweise hohe Rechenzeiten



## 2.1.3 Lastprognose in der Literatur

### *Typische Eingangsvariablen*


i. Stunde des Tages	Kalendervariablen
ii. Tag der Woche	
iii. Arbeits-/Schul-/Feiertag	
iv. Temperatur / Gradient; Mittelwertgefiltert/Max/Min	Wetterdaten*
v. Gefühlte Temperatur	
vi. Windgeschwindigkeit/-richtung	
vii. Relative/absolute Luftfeuchtigkeit	
viii. Solare Einstrahlung	
ix. Gradtagzahl	
x. Vergangene Lastmessungen (Strom, Wärme)	Lastdaten
xi. etc.	weitere

Insgesamt bis zu 50 und mehr Eingangsparameter.


**Aber selten werden Zusammenhänge konkret dargelegt/ausgewertet.**

## 2.1.4 Lastprognose

### Typische Methoden

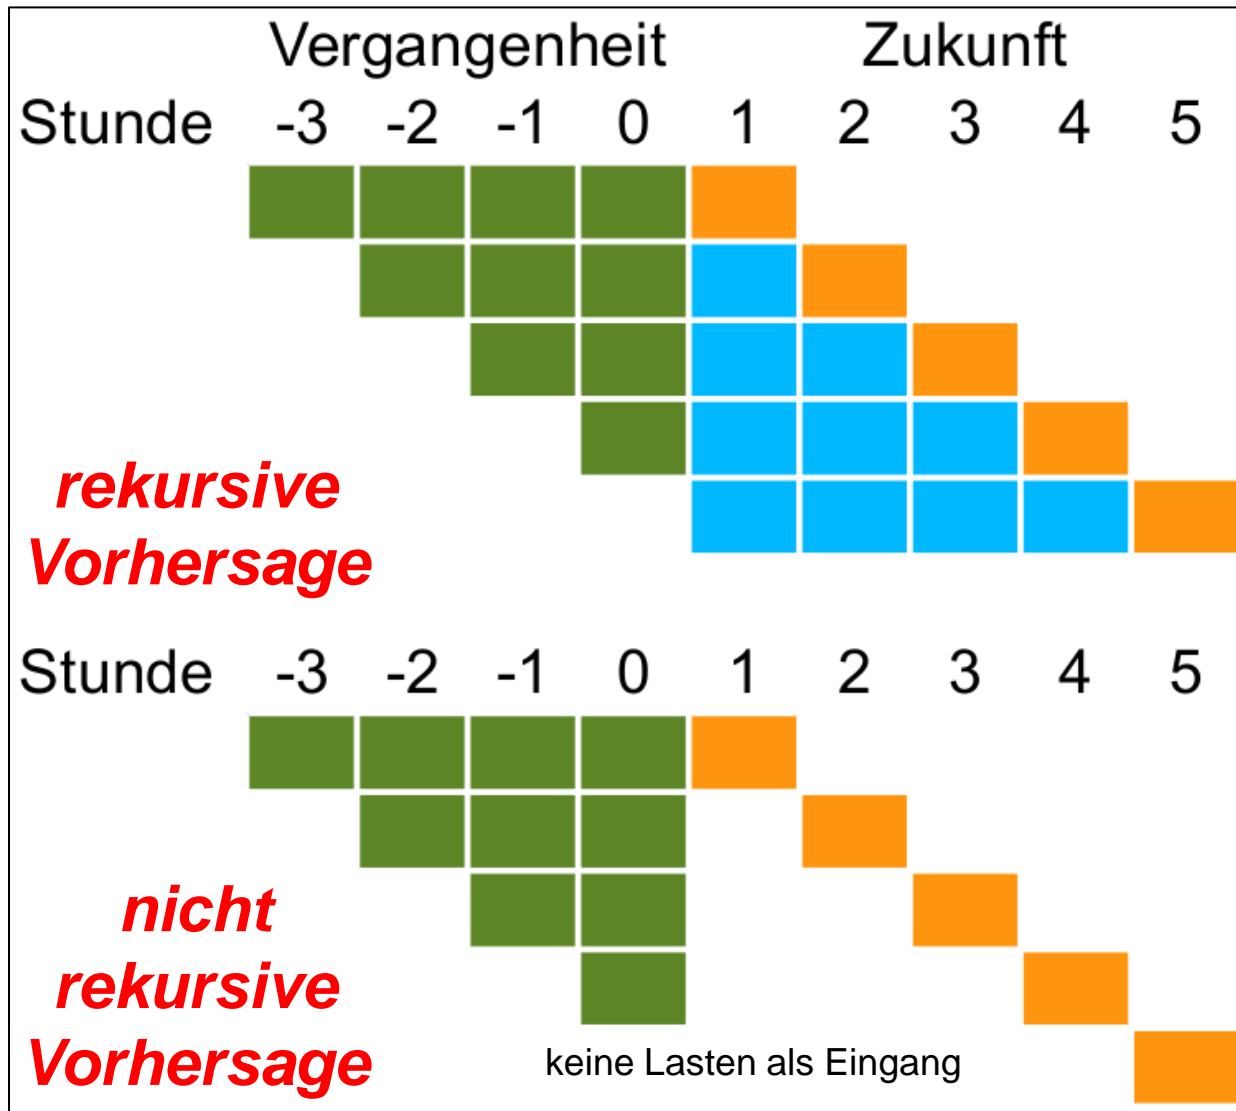


Prognose mehrerer Stunden mit **einem Modell** und Wiederverwendung der Prognose als Eingabeparameter



## 2.1.4 Lastprognose

### Typische Methoden



Prognose mehrerer Stunden mit **einem Modell** und Wiederverwendung der Prognose als Eingabeparameter

gemessene Last  
 prognostizierte Last  
 prognostizierte Last als Eingang

Prognose zu verschiedenen Zeiten mit verschiedenen Eingangsparametern – es ergeben sich **mehrere Modelle**

# 3. Daten

- **Staatliches Baumanagement Hannover, Bürogebäude (SBN)**

- 1h Auflösung
- ca. 1½ Jahre Messungen der Heizlast



**Staatliches Baumanagement  
Niedersachsen**

- **Fernwärmenetz Minden Westfalen Weser**

- 1h Auflösung
- 3 Jahre Messdaten der Heizlast




**Energieservice**  
Westfalen Weser

- **DWD Wetterdaten**

- 1h Auflösung
- u. a. Temperatur, Luftfeuchtigkeit, Windgeschwindigkeit; täglich verfügbar

# 4.1 Ergebnisse

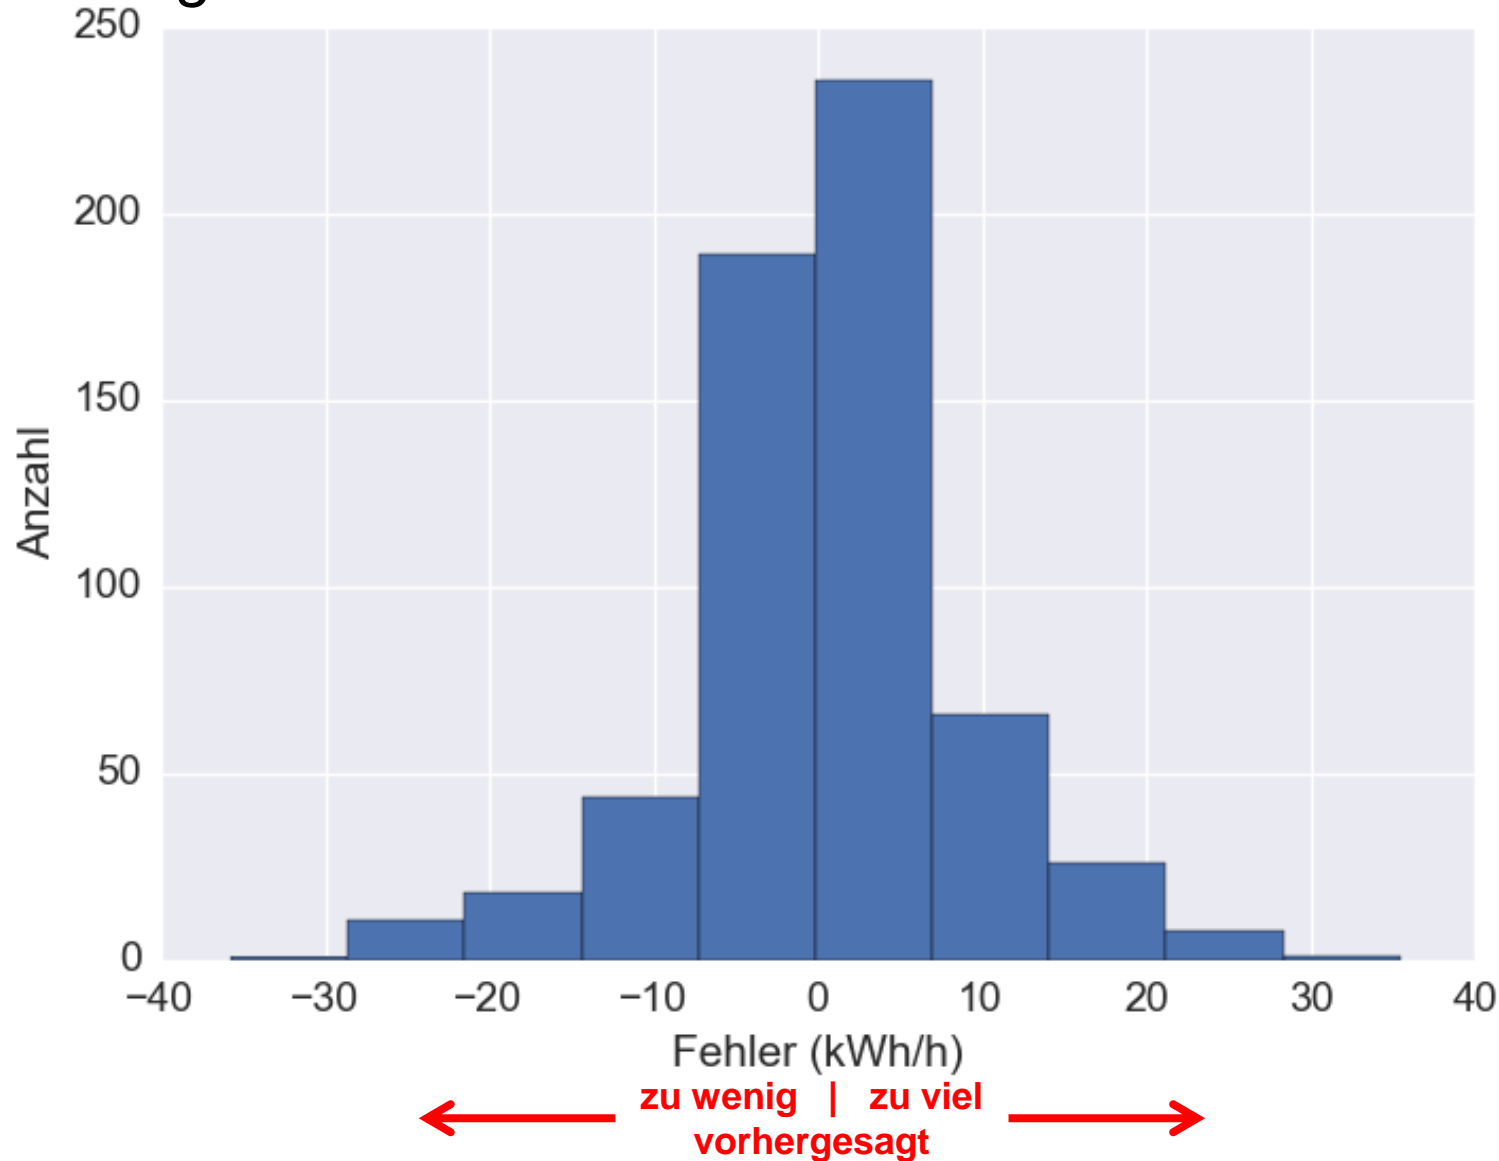
## Bürogebäude



Info	
Datensatz	SBN
Testzeitraum	02-04.2015
Trainingsdaten	ca. 1 Jahr
Update	alle 5 Tage
Intervall	1 Stunde
Verfahren	Gradient Boosting
Variablen	Stunde, Wochentag, Temperatur, vergangene Heizlast, Bewölkung
Ø Last	99.0 kWh/h
Ø abs. Fehler	6.4 kWh/h
Ø abs. %Fehler	7.5 %
95% Intervall	99.5 % der Werte
Ø Breite 95%	22 kWh/h

# 4.1 Ergebnisse

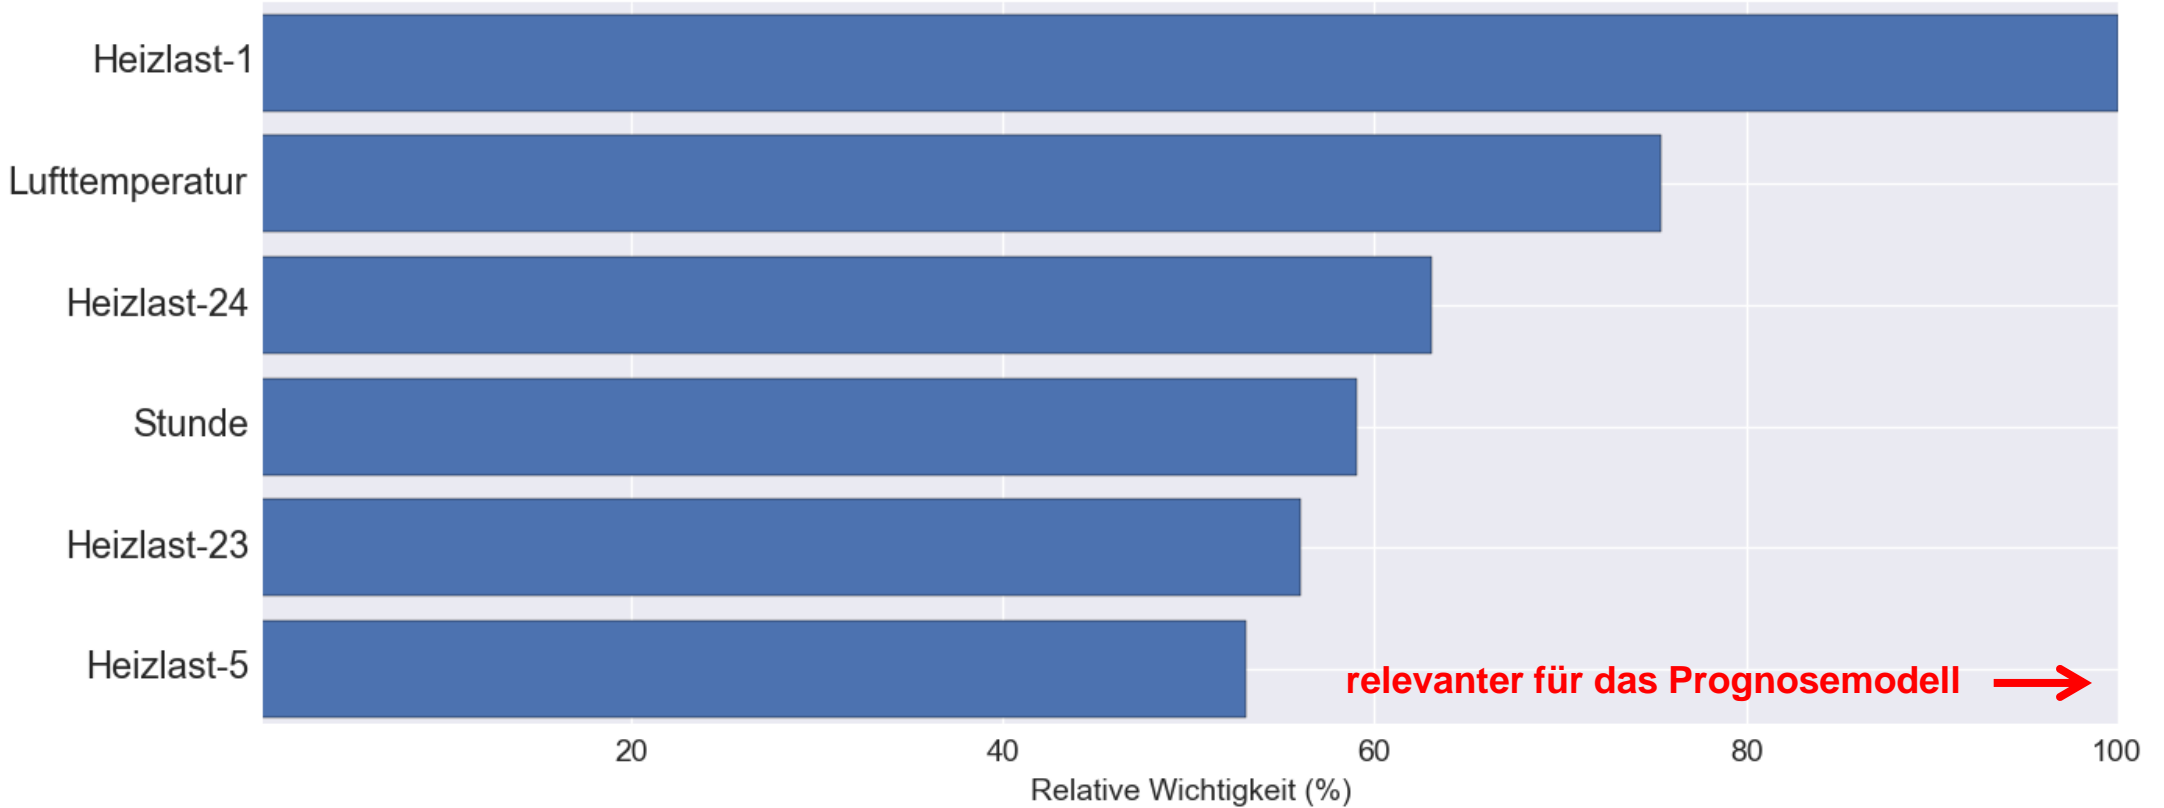
## Bürogebäude



Info	
Datensatz	SBN
Testzeitraum	02-04.2015
Trainingsdaten	ca. 1 Jahr
Update	alle 5 Tage
Intervall	1 Stunde
Verfahren	Gradient Boosting
Variablen	Stunde, Wochentag, Temperatur, vergangene Heizlast, Bewölkung
Ø Last	99.0 kWh/h
Ø abs. Fehler	6.4 kWh/h
Ø abs. %Fehler	7.5 %
95% Intervall	99.5 % der Werte
Ø Breite 95%	22 kWh/h

# 4.1 Ergebnisse


## Bürogebäude



weitere Variablen für Prognose (nicht in Abb.):  
Wochentag, Bewölkungsgrad, Heizlasten

# 4.1 Ergebnisse

## Bürogebäude




Info	
Datensatz	SBN
Testzeitraum	02-04.2015
Trainingsdaten	ca. 1 Jahr
Update	-
Intervall	1 bis 24 Stunden
Verfahren	Gradient Boosting
Variablen	Stunde, Wochentag, Temperatur, vergangene Heizlast, Bewölkung
Ø Last	99.0 kWh/h
Ø abs. Fehler	6.4 – 10.2 kWh/h
Ø abs. %Fehler	7.5 - 12.8 %



# 4.2 Ergebnisse

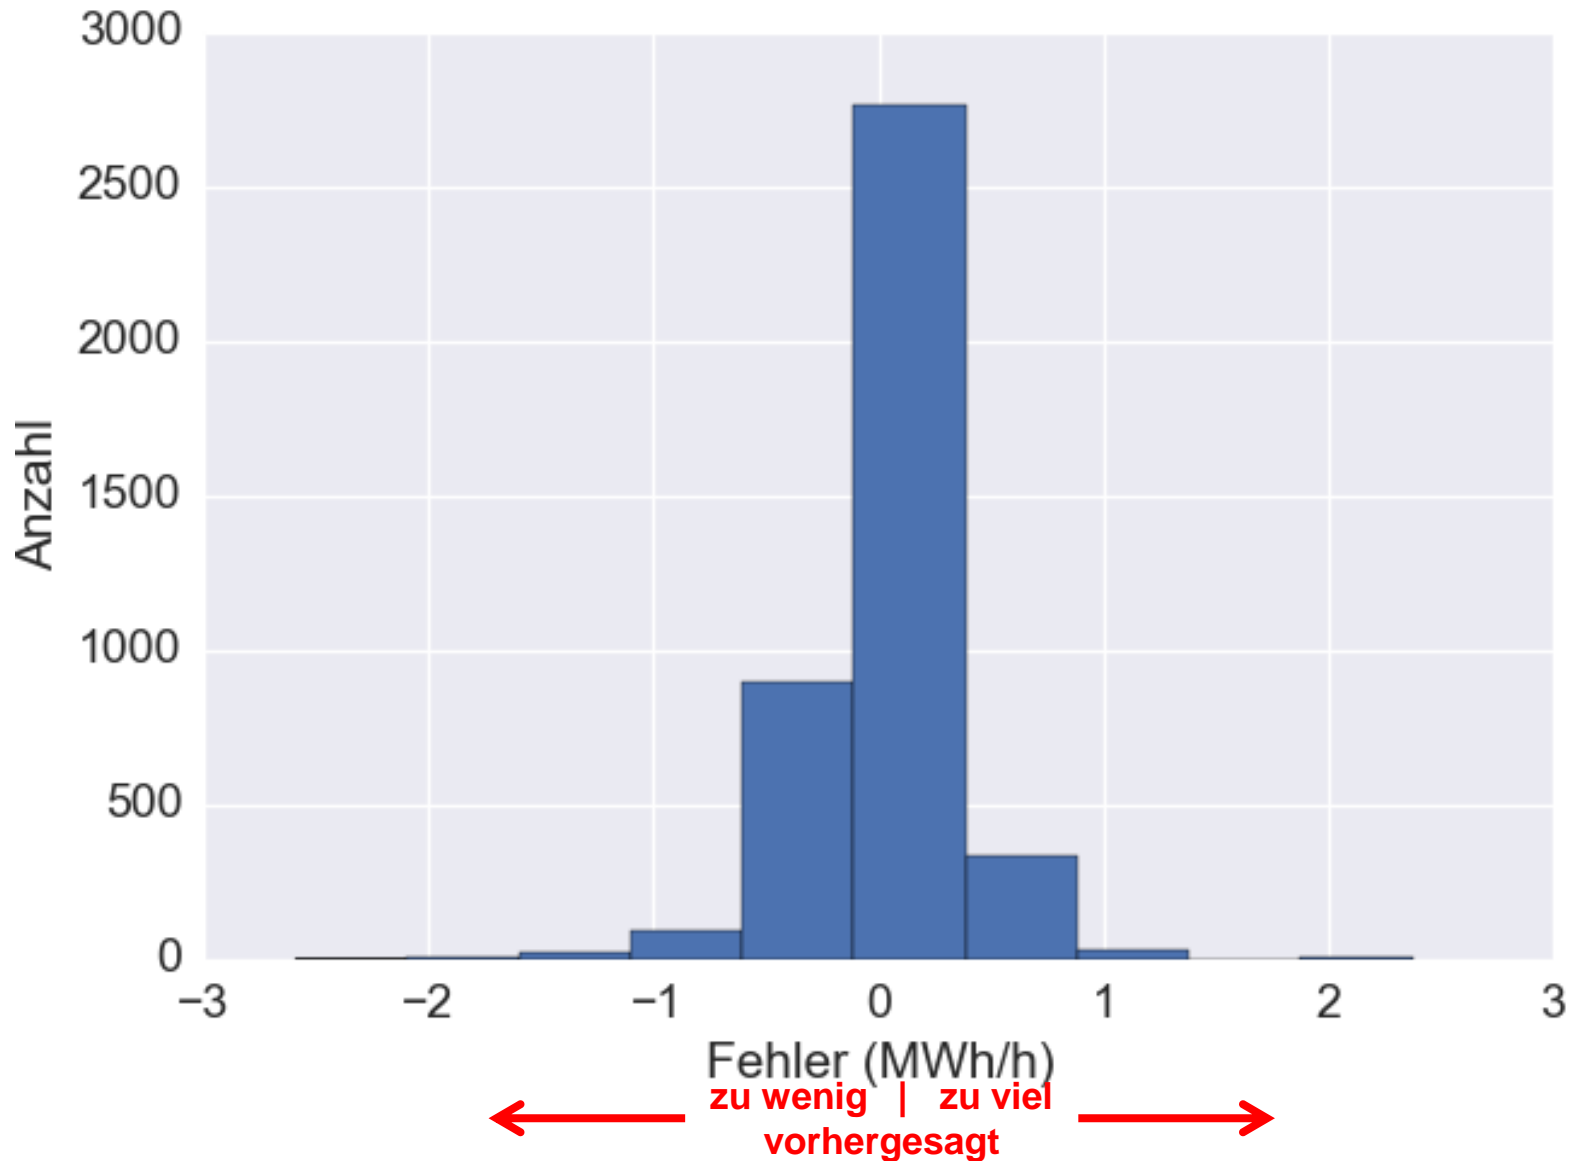
## Fernwärmenetz



Info	
Datensatz	Fernwärme
Testzeitraum	01-06.2013 (6 Monate)
Trainingsdaten	2 Jahre
Update	-
Intervall	1 Stunde
Verfahren	Gradient Boosting
Variablen	Stunde, Wochentag, Temperatur, vergangene Heizlast, Bewölkung
Ø Last	3.57 MWh/h
Ø abs. Fehler	0.21 MWh/h
Ø abs. %Fehler	8.0 %
95% Intervall	99.8% der Werte
Ø Breite 95%	0.96 MWh/h

# 4.2 Ergebnisse


## Fernwärmenetz



Info	
Datensatz	Fernwärme
Testzeitraum	01-06.2013 (6 Monate)
Trainingsdaten	2 Jahre
Update	-
Intervall	1 Stunde
Verfahren	Gradient Boosting
Variablen	Stunde, Wochentag, Temperatur, vergangene Heizlast, Bewölkung
Ø Last	3.57 MWh/h
Ø abs. Fehler	0.21 MWh/h
Ø abs. %Fehler	8.0 %
95% Intervall	99.8% der Werte
Ø Breite 95%	0.96 MWh/h

# 4.2 Ergebnisse

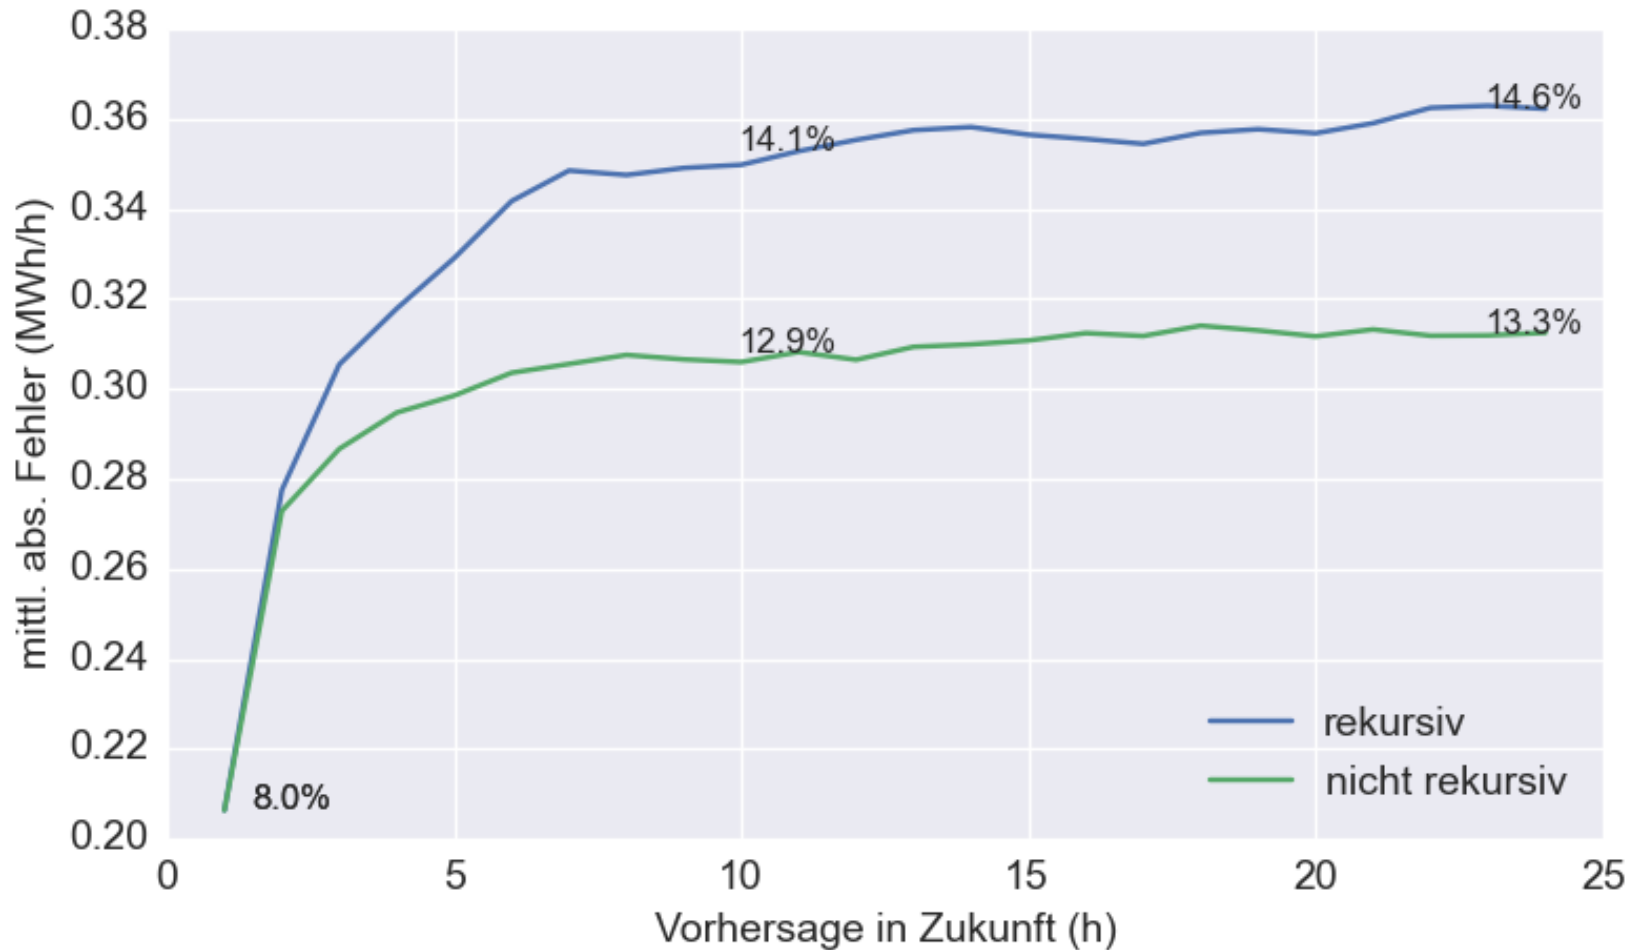
## Fernwärmenetz



weitere Variablen für Prognose (nicht in Abb.):  
Wochentag, Bewölkungsgrad, Heizlasten

# 4.2 Ergebnisse

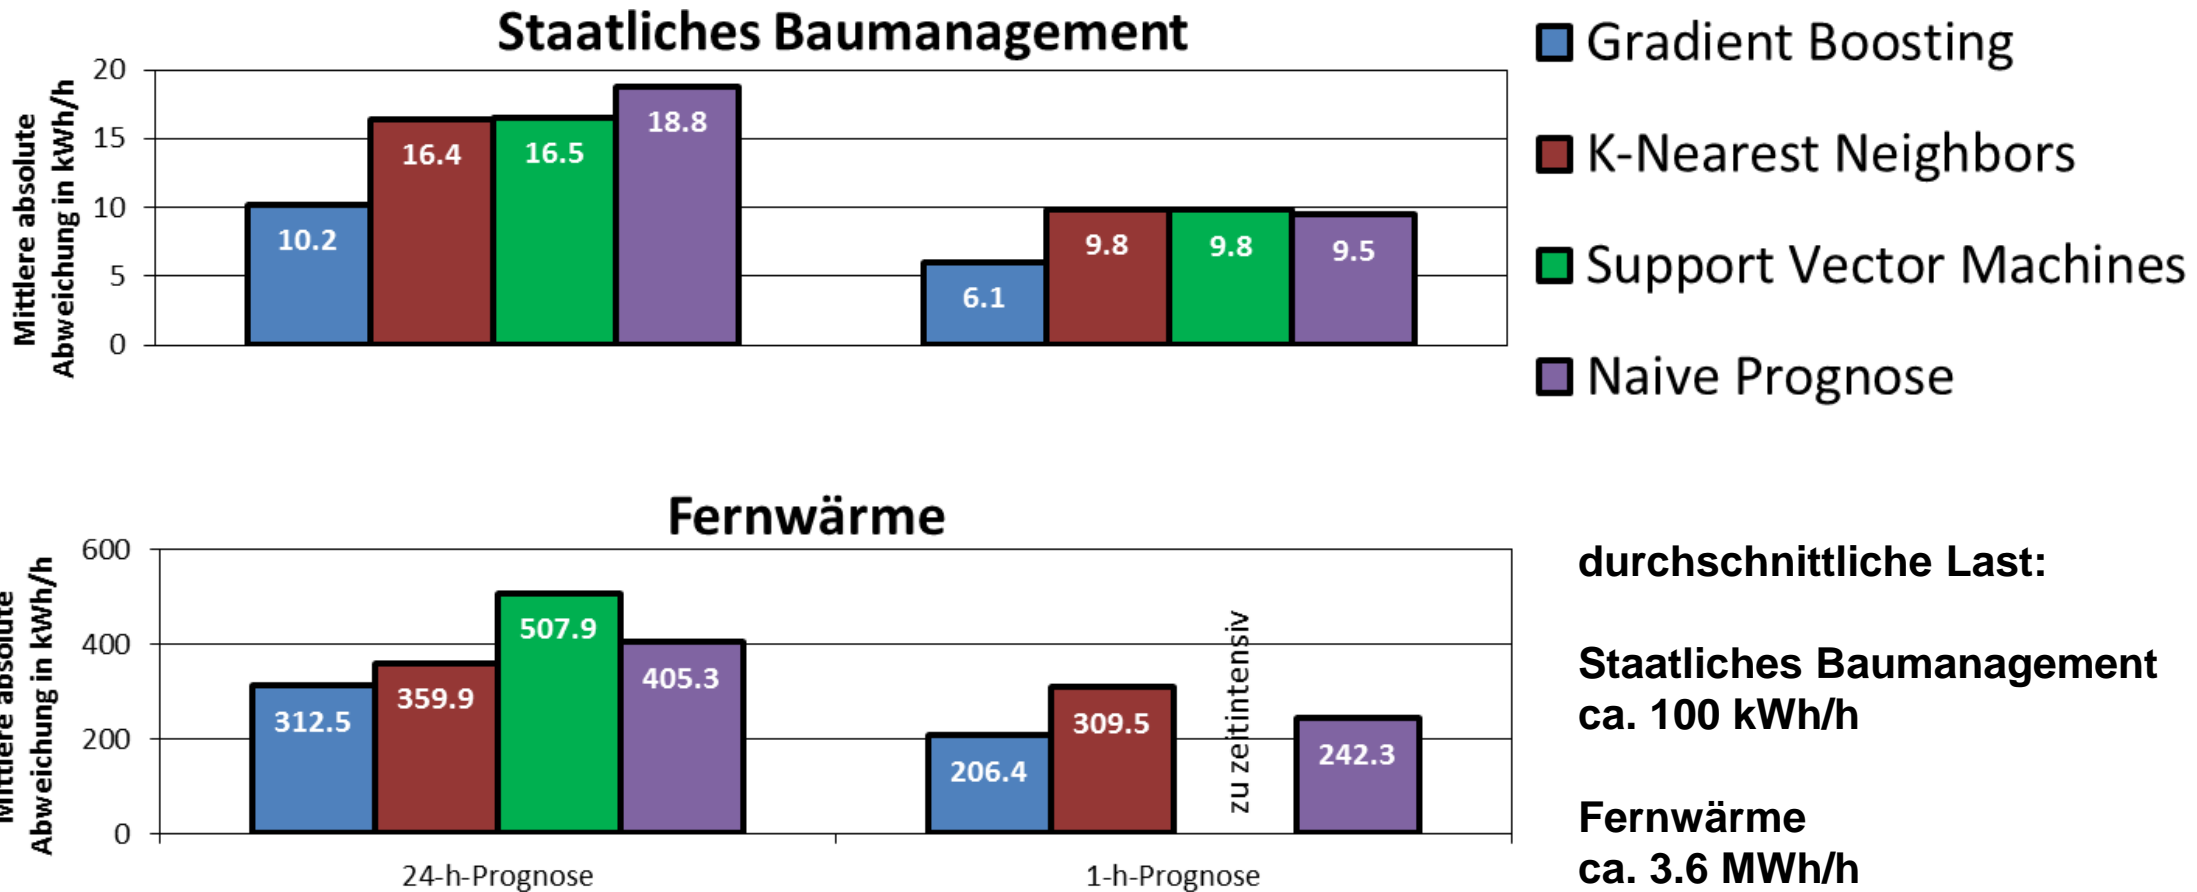
## Fernwärmenetz



Info	
Datensatz	Fernwärme
Testzeitraum	01-06.2013 (6 Monate)
Trainingsdaten	2 Jahre
Update	-
Intervall	1 bis 24 Stunden
Verfahren	Gradient Boosting
Variablen	Stunde, Wochentag, Temperatur, vergangene Heizlast, Bewölkung
Ø Last	3.57 MWh/h
Ø abs. Fehler	0.21 – 0.36 MWh/h
Ø abs. %Fehler	8 - 15 %

# 4.3 Ergebnisse

## Vergleich der Vorhersageverfahren



# 5. Zusammenfassung

- Bürogebäude- und Fernwärmedaten lassen sich ähnlich gut vorhersagen ( $\emptyset$ -Fehler zwischen 7-15%)
- Gradient Boosting bietet viele Vorteile gegenüber anderen Verfahren
- vergangene Heizlasten haben den größten Einfluss auf die Prognosegenauigkeit
- Kalendereffekte (Stunde, Wochentag) und die Temperatur sind wichtig
- bereits mit wenigen Variablen lassen sich gute Ergebnisse erzielen
- nicht rekursive Vorhersage ist bis zu 1.3% besser als rekursive
- die Prognosegenauigkeit nimmt für weiter in der Zukunft liegende Zeiten ab

# 5. Ausblick

- **Vorhersage**
  - Kombination von Gradient Boosting mit neuronalen Netzen
  - Wie wirken sich Fehler in Wetterprognosen aus? Fehlerabschätzung
- **Energiemanagementsystem**
  - Fahrplanerstellung für BHKW und Wärmepumpen
  - Ausnutzung der Prognosen und Prognoseintervalle
  - Bestimmung des ökonomischen und ökologischen Vorteils
- **Testbetrieb** des BHKW an der Hochschule Hannover anhand generierter Fahrpläne




# Vielen Dank für Ihre Aufmerksamkeit!



Wissenschaftliche  
Unterstützung



Technische  
Unterstützung  
Software



Technische Unterstützung  
Betrieb und Anwendung

Frithjof Fehsenfeld  
Hochschule Hannover - Institut für  
Verfahrenstechnik, Energietechnik und Klimaschutz  
Ricklinger Stadtweg 120  
30449 Hannover  
[frithjof.fehsenfeld@hs-hannover.de](mailto:frithjof.fehsenfeld@hs-hannover.de)  
0511 9296 1665



# Referenzen

Ben Taieb, S., & Hyndman, R. J. (2014). A gradient boosting approach to the Kaggle load forecasting competition. *International Journal of Forecasting*, 30(2), 382–394. doi:10.1016/j.ijforecast.2013.07.005

Friedman, J. H. (1999). Greedy Function Approximation: A Gradient Boosting Machine. *The Annals of Statistics*, 29(5), 1189–1232. Retrieved from <http://luthuli.cs.uiuc.edu/~daf/courses/optimization/Papers/2699986.pdf>

Friedman, J. H. (2002). Stochastic gradient boosting. *Computational Statistics and Data Analysis*, 38(4), 367–378. doi:10.1016/S0167-9473(01)00065-2

Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning*. New York, NY: Springer New York. doi:10.1007/b94608

Lloyd, J. R. (2014). GEFCom2012 hierarchical load forecasting: Gradient boosting machines and Gaussian processes. *International Journal of Forecasting*, 30(2), 369–374. doi:10.1016/j.ijforecast.2013.07.002

Pedregosa, F., Weiss, R., & Brucher, M. (2011). Scikit-learn : Machine Learning in Python, 12, 2825–2830.

# Gradient Boosting

## Idee:

Anstatt eines starken Modells werden viele schwache Modelle generiert. Die Menge der schwachen Modelle - *das Ensemble* - bildet das starke Modell.

## Verfahren:

Typischerweise wird ein additives Modell in der Form

$$h(x) = \sum_{i=1}^M h_i(x)$$

erstellt. Dabei wird in jedem Schritt ein schwacher Lerner  $h_i$  an den *Gradienten* des vorherigen Fehlers angepasst (Gradienten-Verfahren). Häufig werden flache Binärbäume (Classification and Regression Tree, CART) als schwache Lerner benutzt.




Abb.: Beispiel eines CAR-Baumes (Hastie et. al. 2009)