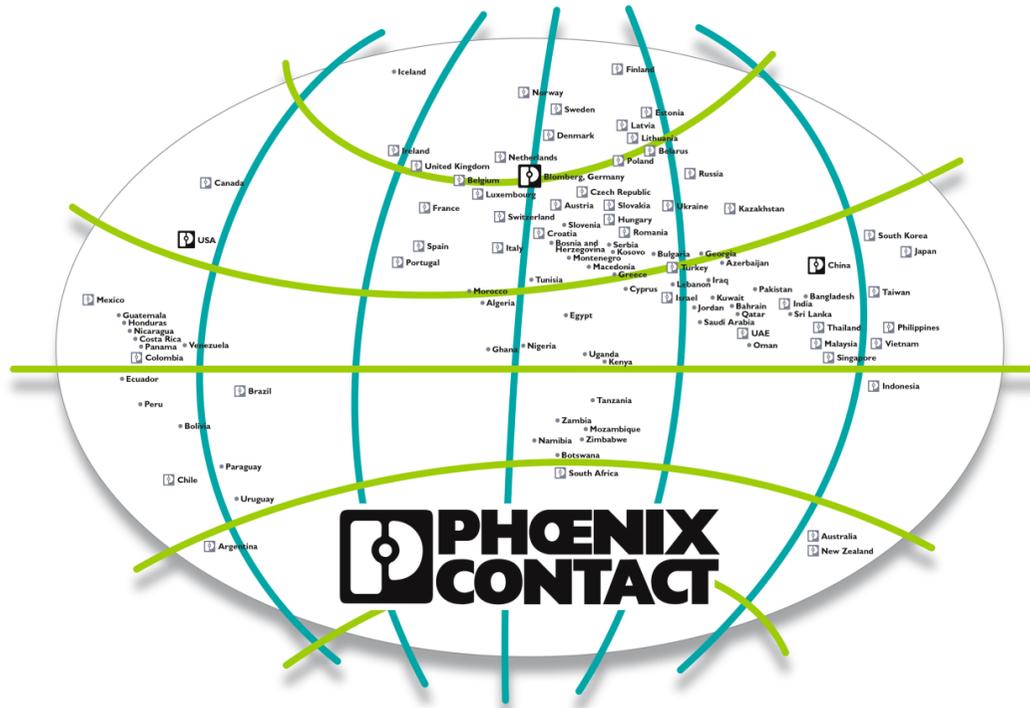


David Nieslony, Phoenix Contact Deutschland GmbH

Ein selbstlernendes System zur Identifikation von Lastgang-Anomalien mithilfe von Algorithmen des maschinellen Lernens



Agenda

- Aktuelle Situation
- Allgemein: Algorithmen und Verfahren auf Datenmengen
- Prognose des Lastganges
- Vergleich von Prognose und tatsächlich aufgetretenen Werten
- Ableiten von Aktionen aus Prognosen

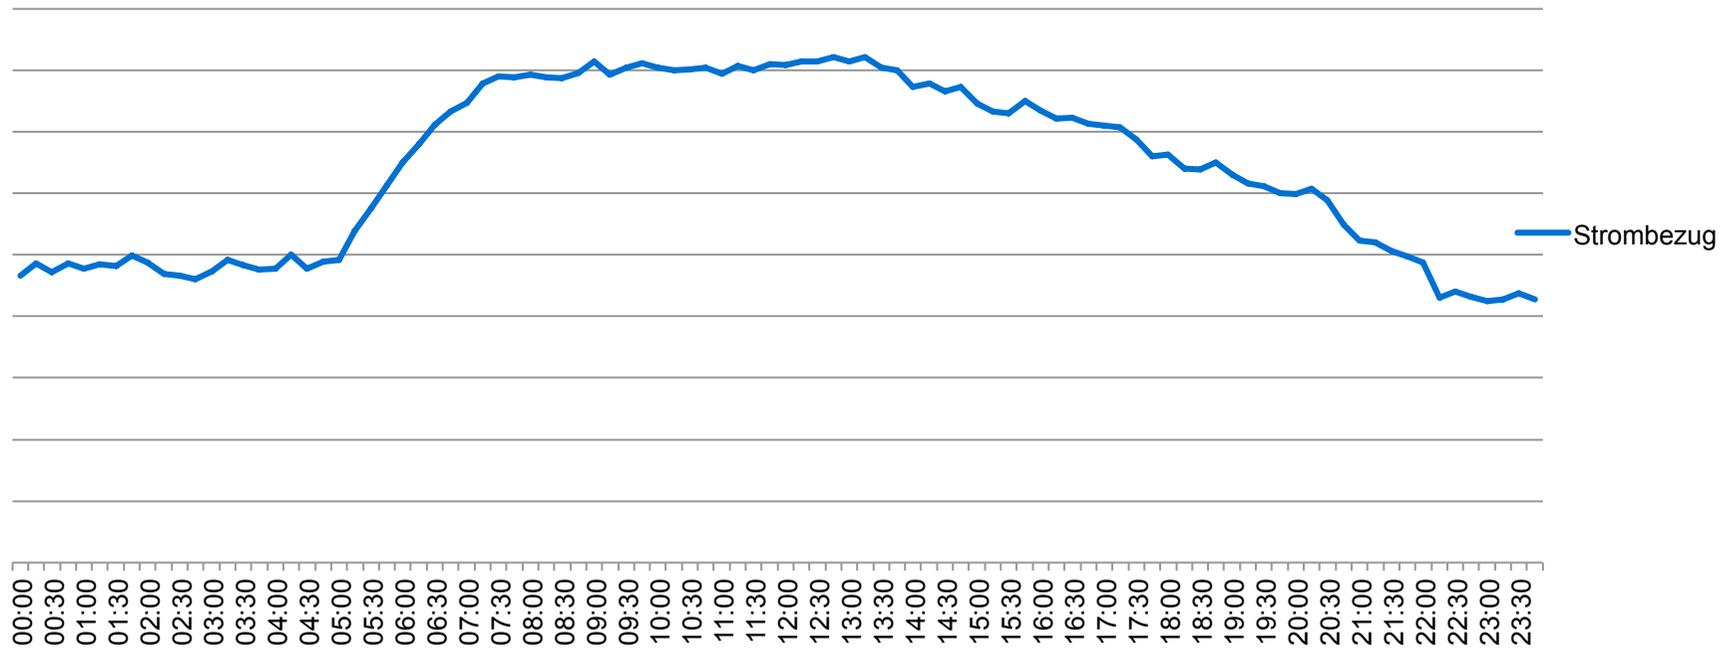
Aktuelle Situation

Allgemein

- Standort bezieht Energie vom Energieversorgungsunternehmen (EVU)
- Eigene Stromproduktion durch verschiedene Erzeuger
- Stromkosten setzen sich neben Gesamtverbrauch aus der höchsten Strombezugsspitze zusammen
- Es treten sporadisch Peaks auf, welche hohe Kosten mit sich ziehen können

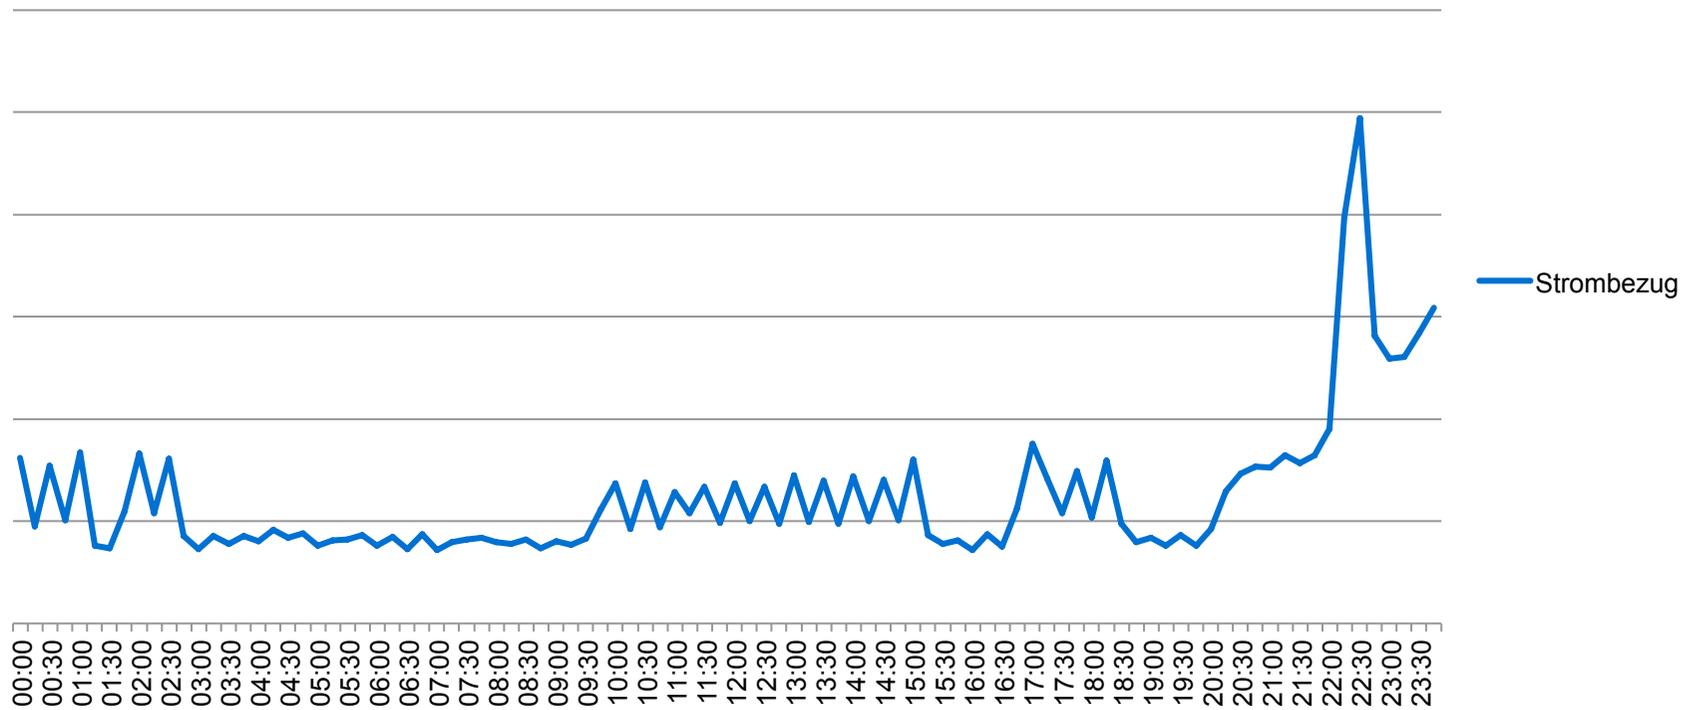
Aktuelle Situation

Lastkurven: Normalverlauf - Werktags



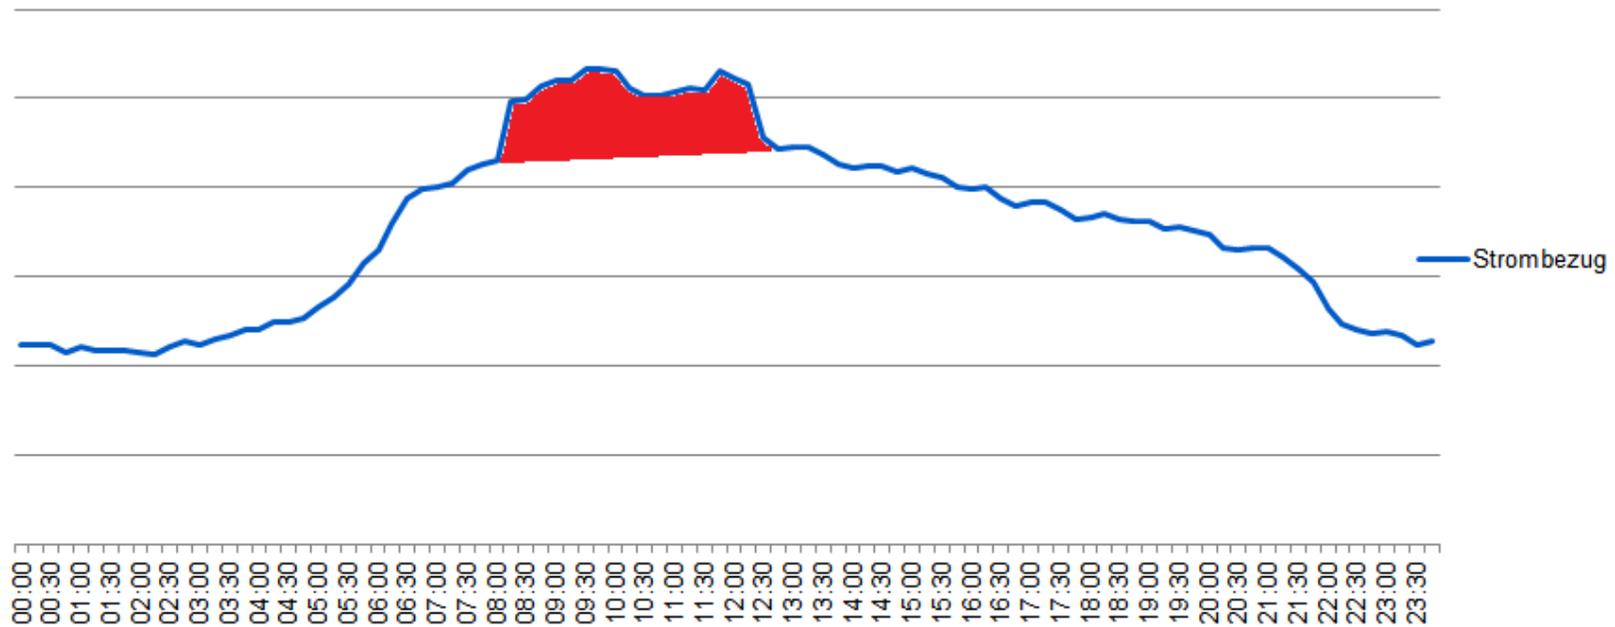
Aktuelle Situation

Lastkurven: Normalverlauf - Wochenende



Aktuelle Situation

Lastkurven: Anomalie



Aktuelle Situation

Resultierende Fragestellungen

- Resultierende Fragestellungen:
 - Existieren Korrelationen innerhalb der verschiedenen Energiedaten?
 - Lassen sich Strombezüge in Cluster aufteilen?
 - Kann der Strombezug prognostiziert werden?
 - Gelangen unterschiedliche Algorithmen zu unterschiedlichen Ergebnissen?

Algorithmen und Verfahren auf Datenmengen

Korrelationsanalyse

- Korrelationen erkennen mittels Korrelationsanalyse:

$$r_k = \frac{\sum_{i=1}^n (x_i - \bar{x}) * (y_i - \bar{y})}{\sqrt{\left(\sum_{i=1}^n x_i^2 - n * (\bar{x})^2\right) * \left(\sum_{i=1}^n y_i^2 - n * (\bar{y})^2\right)}}$$

- Korrelationskoeffizient r_k im Intervall: $[-1, 1]$
- Dabei gilt: $r_k = 0 \rightarrow$ keine Korrelation

KMeans

- Clusteranalyse (KMeans):
 - Eingruppierung der Datensätze in Cluster
 - Ziel: Wert der Zielfunktion zu minimieren

$$wc(C) = \sum_{k=1}^K wc(C_k) = \sum_{k=1}^K \sum_{x(i) \in C_k} d(x, r_k)^2$$

- Cluster ist durch seinen Mittelpunkt definiert
- Für jeden Cluster C_k werden die quadrierten Abstände aller Datenpunkte x zum Zentrum des Cluster r_k aufsummiert

Algorithmen und Verfahren auf Datenmengen

Übersicht: Klassifikationsverfahren

- Prognose des Strombezugs:
 - Einbezogene Verfahren:
 - Künstliches neuronales Netz
 - K-Nearest-Neighbors
 - Support-Vector-Machine
 - Unterschiede in den Ergebnissen und der Machbarkeit

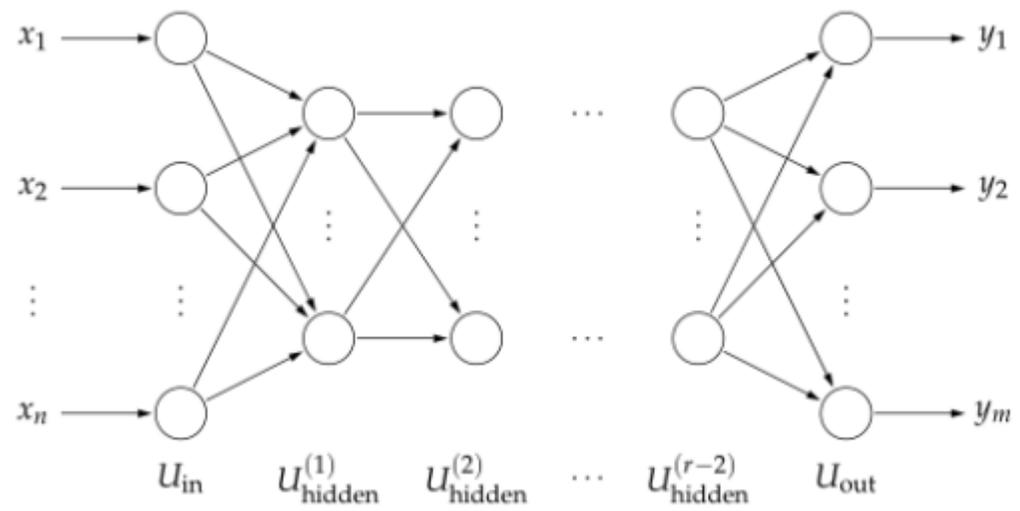
Algorithmen und Verfahren auf Datenmengen

Künstliche neuronale Netze

- Künstliches neuronales Netz:
 - Orientierung an der Funktionsweise des menschlichen Nervensystems
 - Allerdings: stark vereinfacht
 - Zwei unterschiedliche Arten:
 - Einfaches Perzeptron
 - Für linear separierbare Probleme
 - Mehrschichtiges Perzeptron
 - Für komplexe, nicht linear separierbare Probleme

Algorithmen und Verfahren auf Datenmengen

Multi-Layer Perceptron

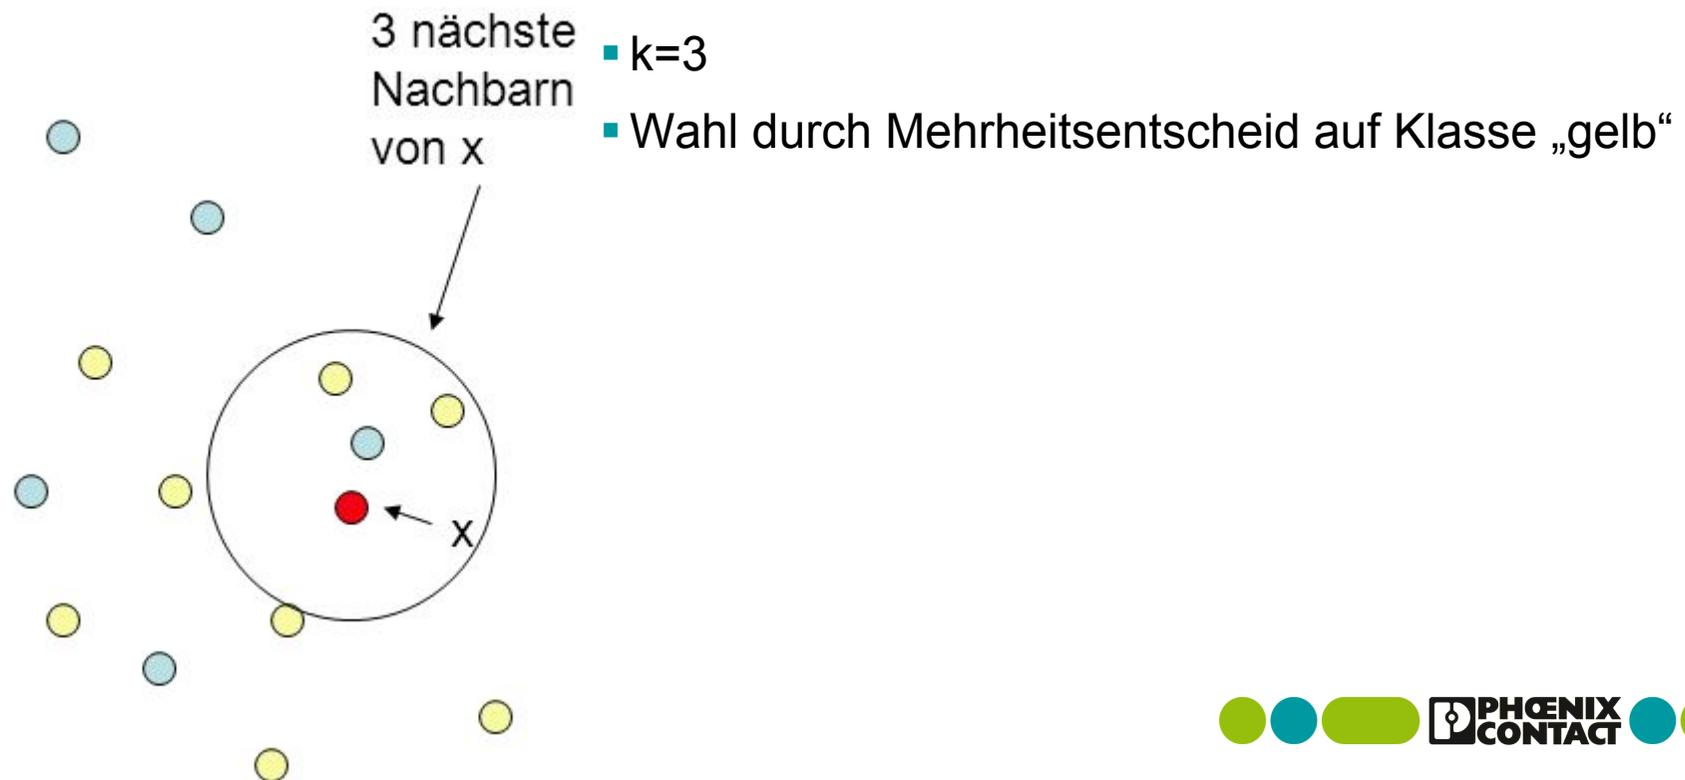


Algorithmen und Verfahren auf Datenmengen

K-Nearest-Neighbors

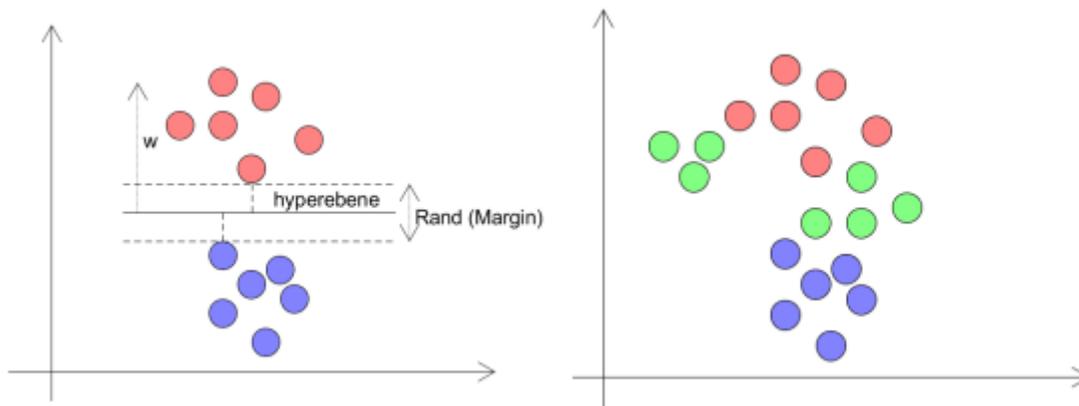
- K-Nearest-Neighbors:
 - Unterschied zum MLP:
 - Kein konkretes Modell notwendig
 - Werte werden in Abhängigkeit ihrer nächsten Nachbarn klassifiziert
 - Im Vorfeld muss ein Parameter k gewählt werden

K-Nearest-Neighbors



Support Vector Machine

- Support Vector Machine:
 - Sehr komplex für das vorliegende Problem
 - Aufteilung in sehr viele Klassen notwendig: > 5000
 - Wieder: Lineare vs. nicht-lineare Separierbarkeit



Algorithmen und Verfahren auf Datenmengen

Support Vector Machine

- Ziel:
 - n viele Hyperebenen finden
 - Hyperebenen mit möglichst maximalen Abstand zu Datenpunkten der verschiedenen Klassen
- Problem:
 - Wesentlich zeitintensiver als neuronales Netz und k-nächste Nachbarn

Prognose des Lastganges

Merkmalsvektoren

- Zwei Varianten:
 - Variante 1:
 - Unabhängige Prognose für:
 - Strombezug
 - Stromproduktion
 - 5 Merkmale, $[x_1, \dots, x_5]$

Prognose des Lastganges

Merkmalsvektoren

- Variante 2:
 - Strombezug in Abhängigkeit von der Produktion
 - Komplexer Merkmalsvektor
 - 17 Merkmale, $[x_1, \dots, x_{17}]$

Prognose des Lastganges

Erkenntnisse der Klassifikation

- Multi-Layer-Perceptron
 - durchschnittliche Dauer der Prognose für den nächsten Zeitpunkt:
 - 120 Sekunden
 - durchschnittliche Abweichungen vom Realwert (Strombezug):
 - an Tagen ohne Anomalie: ~2%
 - an Tagen mit Anomalie: ~ 3 - 5%
 - Andere Parametrisierung erbringt alternative Ergebnisse
 - verdeckte Schicht, Lernrate, Epochen

Prognose des Lastganges

Erkenntnisse der Klassifikation

- K-Nearest-Neighbors
 - durchschnittliche Dauer der Prognose für den nächsten Zeitpunkt:
 - 30 Sekunden
 - durchschnittliche Abweichungen vom Realwert (Strombezug):
 - an Tagen ohne Anomalie: ~1.5%
 - an Tagen mit Anomalie: ~ 2 - 4%

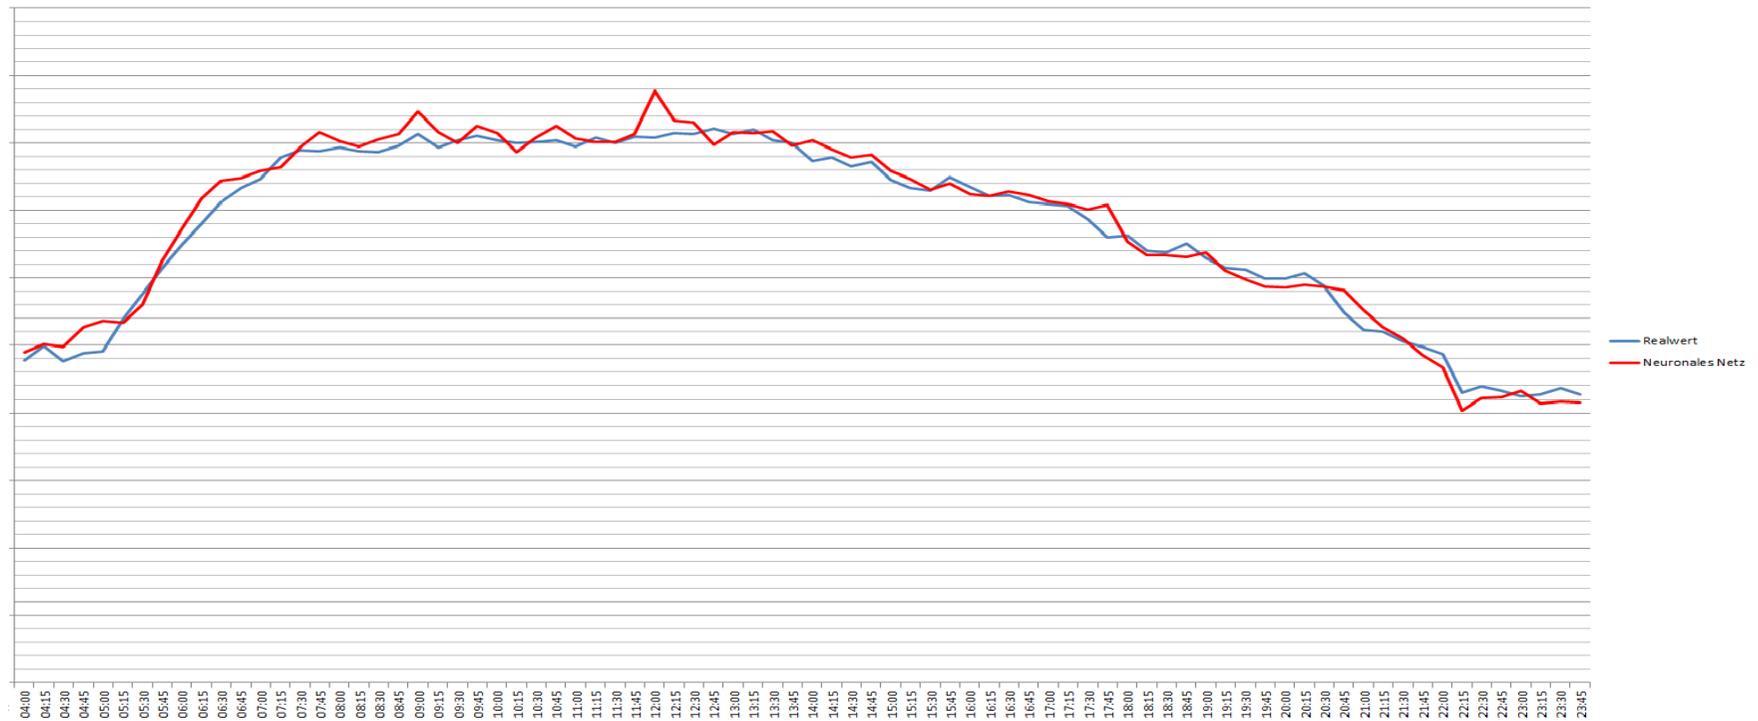
Prognose des Lastganges

Erkenntnisse der Klassifikation

- Support-Vector-Machine
 - nicht möglich
 - Separierbarkeit auf die Fülle der Hyperebenen zu zeitintensiv und zu fehleranfällig

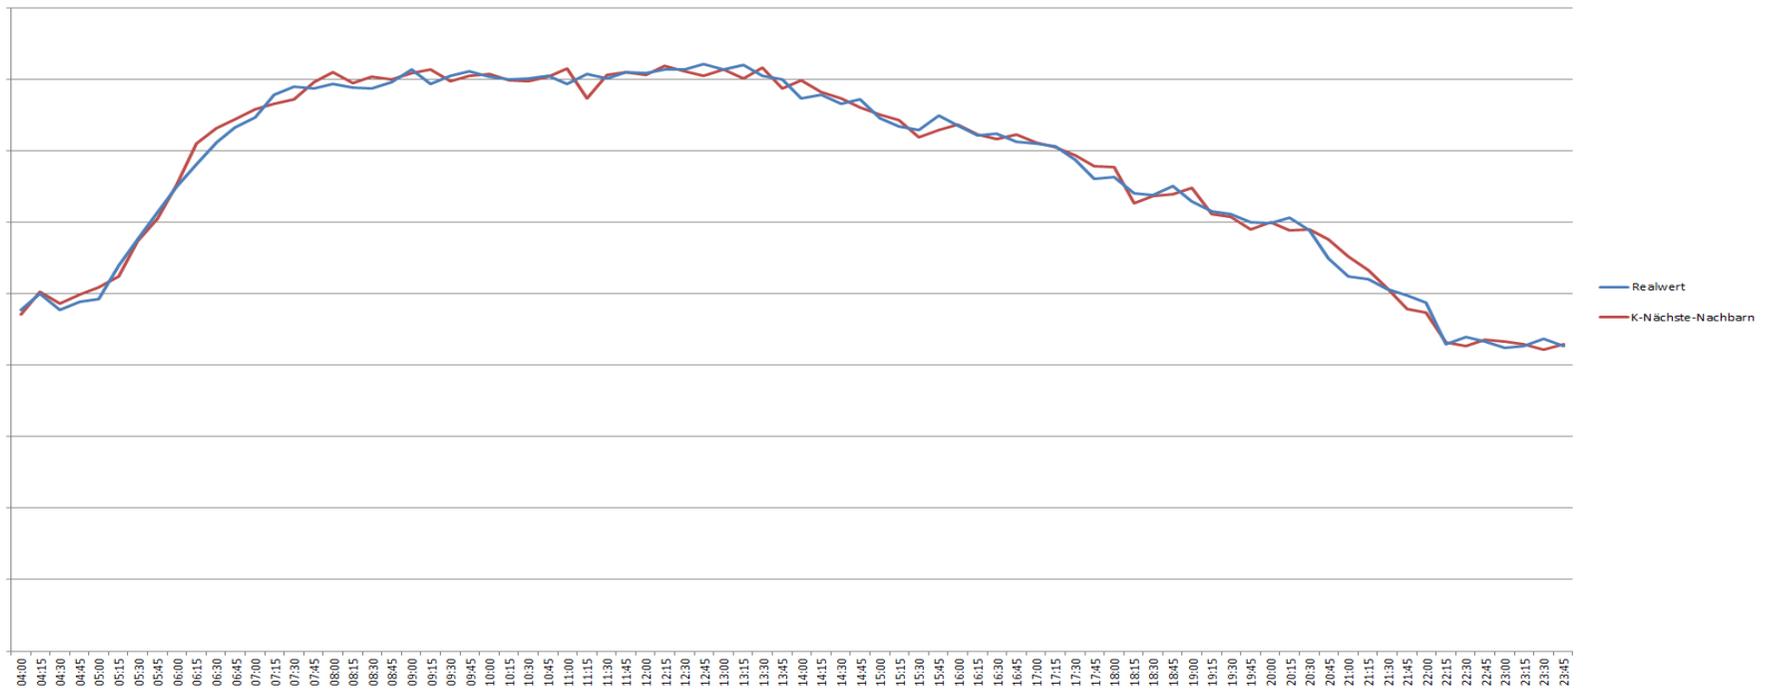
Prognose des Lastganges

Vergleich: MLP ohne Anomalie (Variante 1)



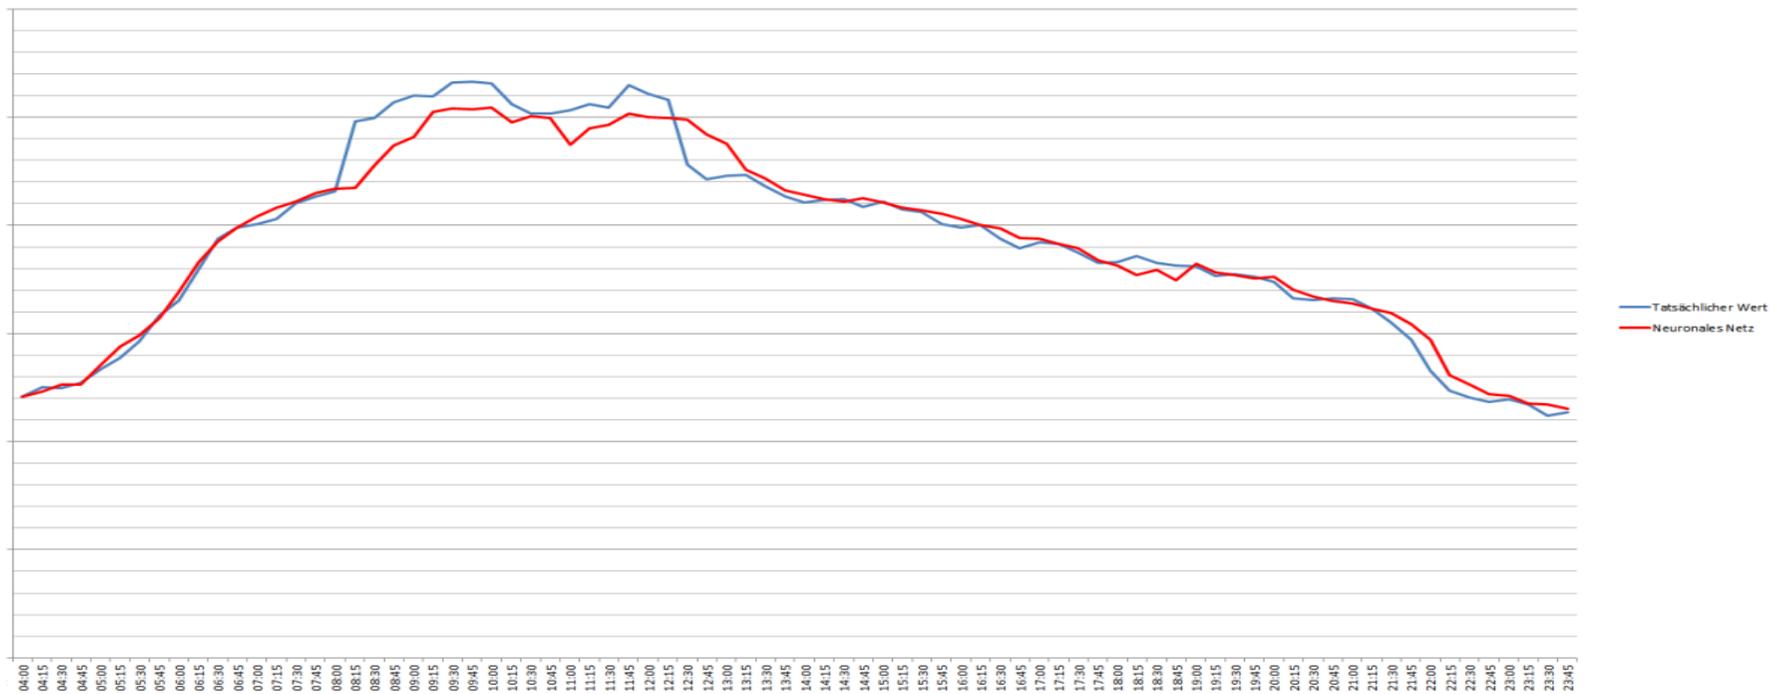
Prognose des Lastganges

Vergleich: KNN ohne Anomalie (Variante 1)



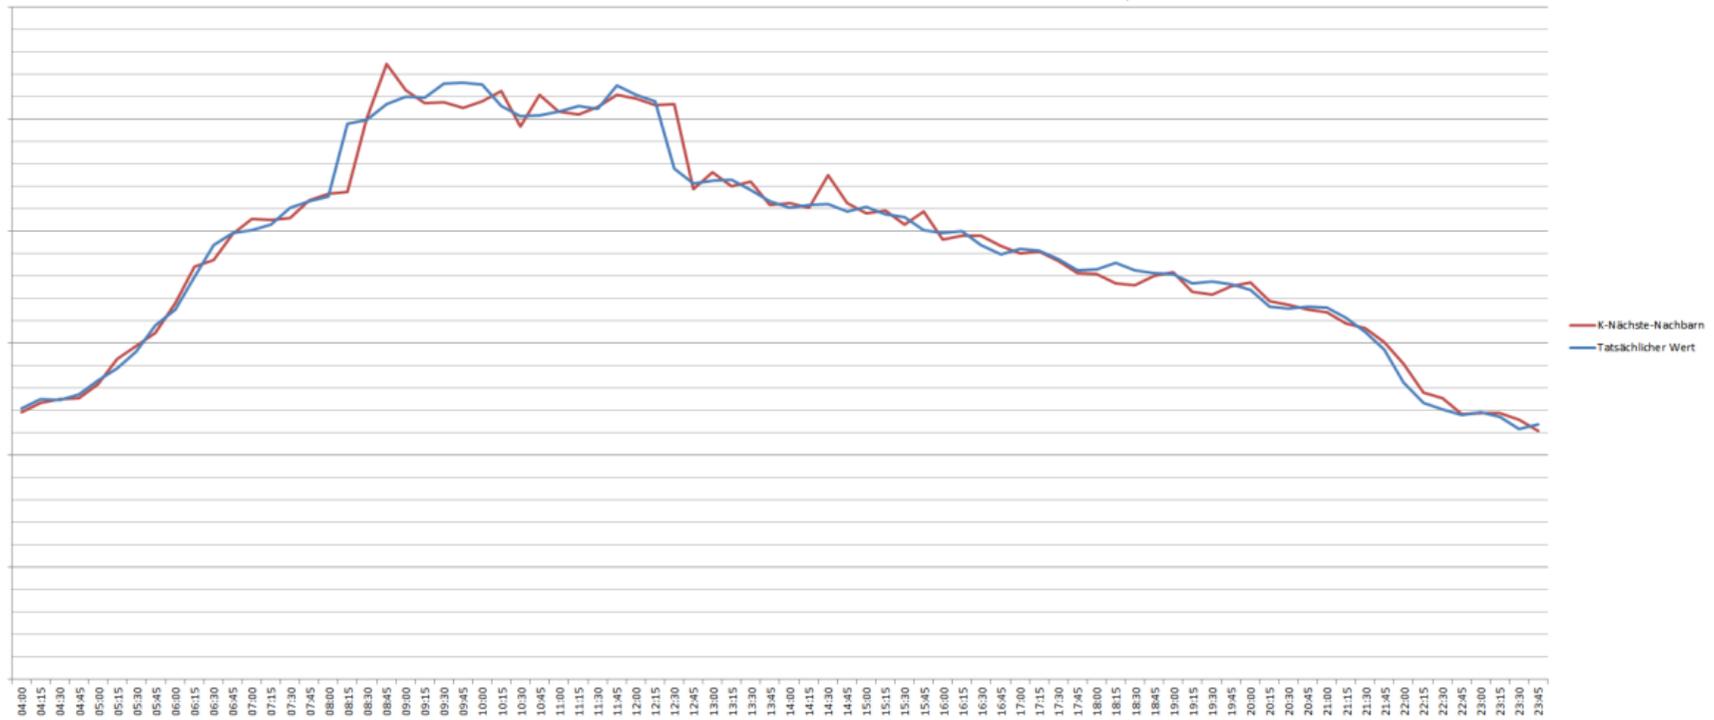
Prognose des Lastganges

Vergleich: MLP mit Anomalie (Variante 1)



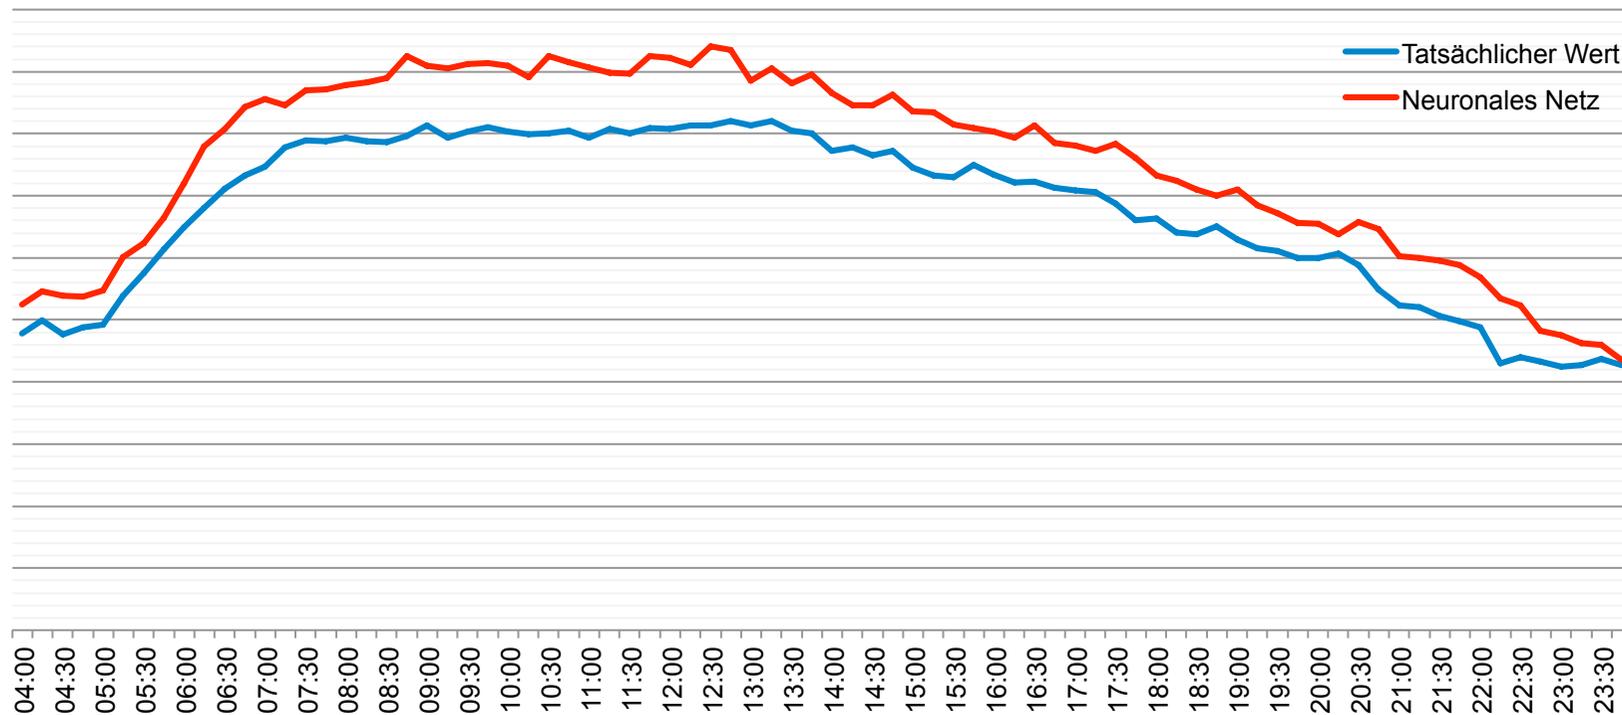
Prognose des Lastganges

Vergleich: KNN mit Anomalie (Variante 1)



Prognose des Lastganges

Vergleich: MLP ohne Anomalie (Variante 2)



Ableiten von Aktionen aus Prognosen

Mögliche Aktionen bei Anomalie-Erkennung

- Lastabwurf unkritischer Verbraucher
 - Belüftungssysteme
 - Beleuchtung
- Intelligente Energiemanagementsysteme
 - Speicherung bei Überproduktion
 - „Reserveenergie“ bei Anomalieauftritt

Zusammenfassung

- Prognose des Strombezuges funktioniert gut (Variante 1)
- Ursachenforschung bezüglich der leichten Zeitversetzung bei der Prognose
- Ursachen müssen in Werten erfasst werden
- Diese Werte könnten als Merkmale verwendet werden

Danke