

# KI IN DER ENERGIETECHNIK

Dr. Sebastian Wende-von Berg mit Beiträgen von  
Zhenqi Wang, Mike Vogt, Arne Wessel, Marcel Dipp & Malte Siefert  
11.11.2021 - Virtuelle Vortragsreihe Künstliche Intelligenz #3



---

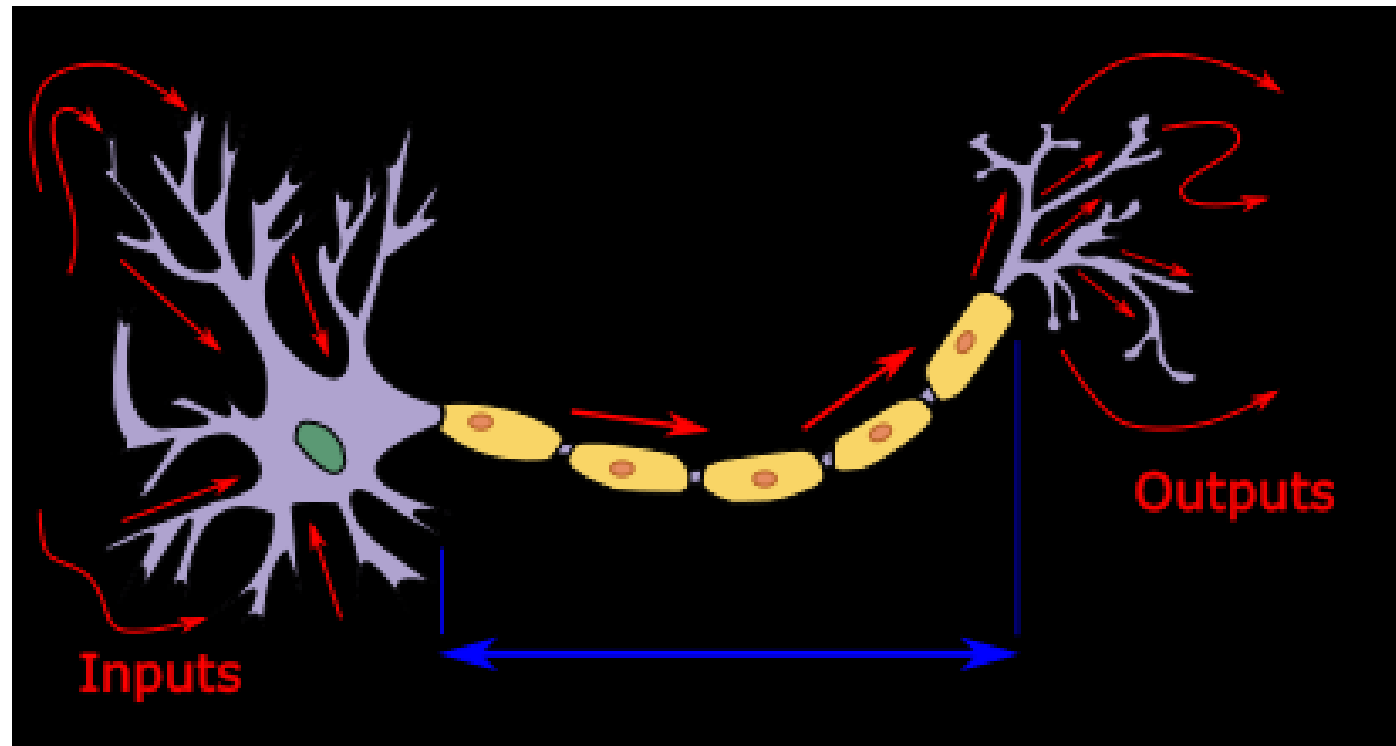
# AGENDA

---

- Übersicht über ausgewählte Methoden der KI
- Aktuelle Anwendungen von KI-Methoden in der Energietechnik
  - Energieprognosen
  - Netzzustandsbestimmung in wenig ausgemessenen Netzen
  - Netzoptimierung mithilfe von KI
- Probabilistische Netzzustandsprognose (Kompetenzzentrum Kognitive Energiesysteme)
- Zusammenfassung & Ausblick

# ÜBERSICHT ÜBER AUSGEWÄHLTE METHODEN DER KI

## Maschinelles Lernen und Künstliche neuronale Netze




# Maschinelles Lernen

- Maschinelles Lernen ist ein Teilgebiet der Informatik
- Es beschäftigt sich mit der Entwicklung von Algorithmen, die eine Ansammlung von Daten zu einem bestimmten Phänomen nutzen
- Verfahren zur Lösung eines Problems mit maschinellem Lernen:
  1. Sammeln von Daten, die für das Problem relevant sind
  2. Verwendung der Daten zur Erstellung eines statistischen Modells (Trainingsphase)
  3. Das Modell kann verwendet werden, um das Problem für neue (unbekannte) Daten zu lösen (Anwendungsphase)

# Verschiedene Arten des Lernens

- Unterschiedliche Aufgaben erfordern verschiedene Arten des „Lernens“

1. Überwachtes Lernen
2. Unüberwachtes Lernen
3. Selbstüberwachtes Lernen




Source: Menke et al  
(<https://www.springer.com/gp/book/9783030427252>)

# Verschiedene Arten des Lernens

- Unterschiedliche Aufgaben erfordern verschiedene Arten des „Lernens“

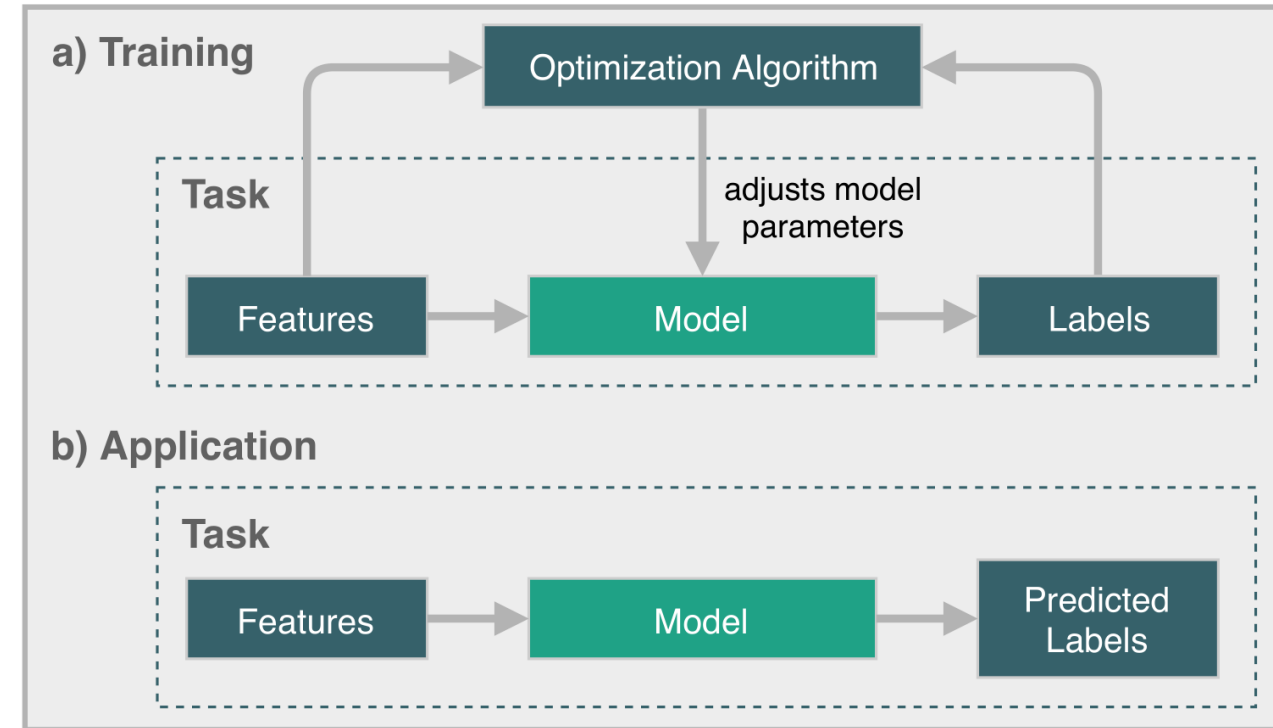
1. Überwachtes Lernen
2. Unüberwachtes Lernen
3. Selbstüberwachtes Lernen



Source: Menke et al  
<https://www.springer.com/gp/book/9783030427252>

# Überwachtes Lernen

- Datensatz besteht aus mehreren Datenpunkten (**Stichproben** genannt)
- Jede Stichprobe enthält Eingaben (**Merkmale** genannt) und passende Ausgaben (**Bezeichnungen** genannt)
- Mathematisches Modell: Lernt eine **Beziehung** zwischen **Merkmalen** und **Bezeichnungen**
  - Trainingsdatensatz und Testdatensatz



- Während des Trainings ändert ein Optimierungsalgorithmus die Parameter des Modells so, dass die Ausgabe des Modells für jede Eingabeprobe mit der Referenzangabe der Probe übereinstimmt.
- In der Anwendungsphase können neue Eingaben in das Modell eingespeist werden, das dann die entsprechende Ausgabe mit hoher Genauigkeit ableitet.

Source: Menke et al  
(<https://www.springer.com/gp/book/9783030427252>)




# Beispiele Überwachtes Lernen 1/2

- Schätzung des angemessenen Preises von Häusern auf der Grundlage einiger Informationen über sie (Anzahl der Zimmer, Wohnfläche, Nachbarschaft, Swimmingpool usw.).

Erbaut Jahr	Fläche [m <sup>2</sup> ]	Anzahl Zimmer	Schwimmbad / Pool	Nachbarschaft [1-5]	Angemessener Preis
1999	260	8	No	4	200 000 €
2005	340	11	Yes	5	390 000 €
....					

- **Handschrifterkennung:** Der Datensatz besteht aus einer Reihe von Merkmalen (Bilder mit numerischen Zeichen) und entsprechenden Bezeichnungen (das Zeichen als Zeichenkette)
- Das Modell lernt, die Bilder der Zeichen in Zeichenfolgen zu übersetzen, so dass gescannte Dokumente automatisch analysiert werden können. (Inputdaten können auch verrauscht werden, so dass die Datengrundlage größer ist)
- Dies ist eine **Klassifizierungsaufgabe** (diskrete Ausgabe)





# Beispiele Überwachtes Lernen 2/2

- Vorhersage von Aktienkursen: Auf der Grundlage von historischen Werten, Fundamentaldaten usw. als Merkmale kann der nächste Schlusskurs einer Aktie (theoretisch) vorhergesagt werden.
- Da der Preis eine Fließkommazahl (kontinuierlich) ist, wird dies als **Regressionsaufgabe** bezeichnet

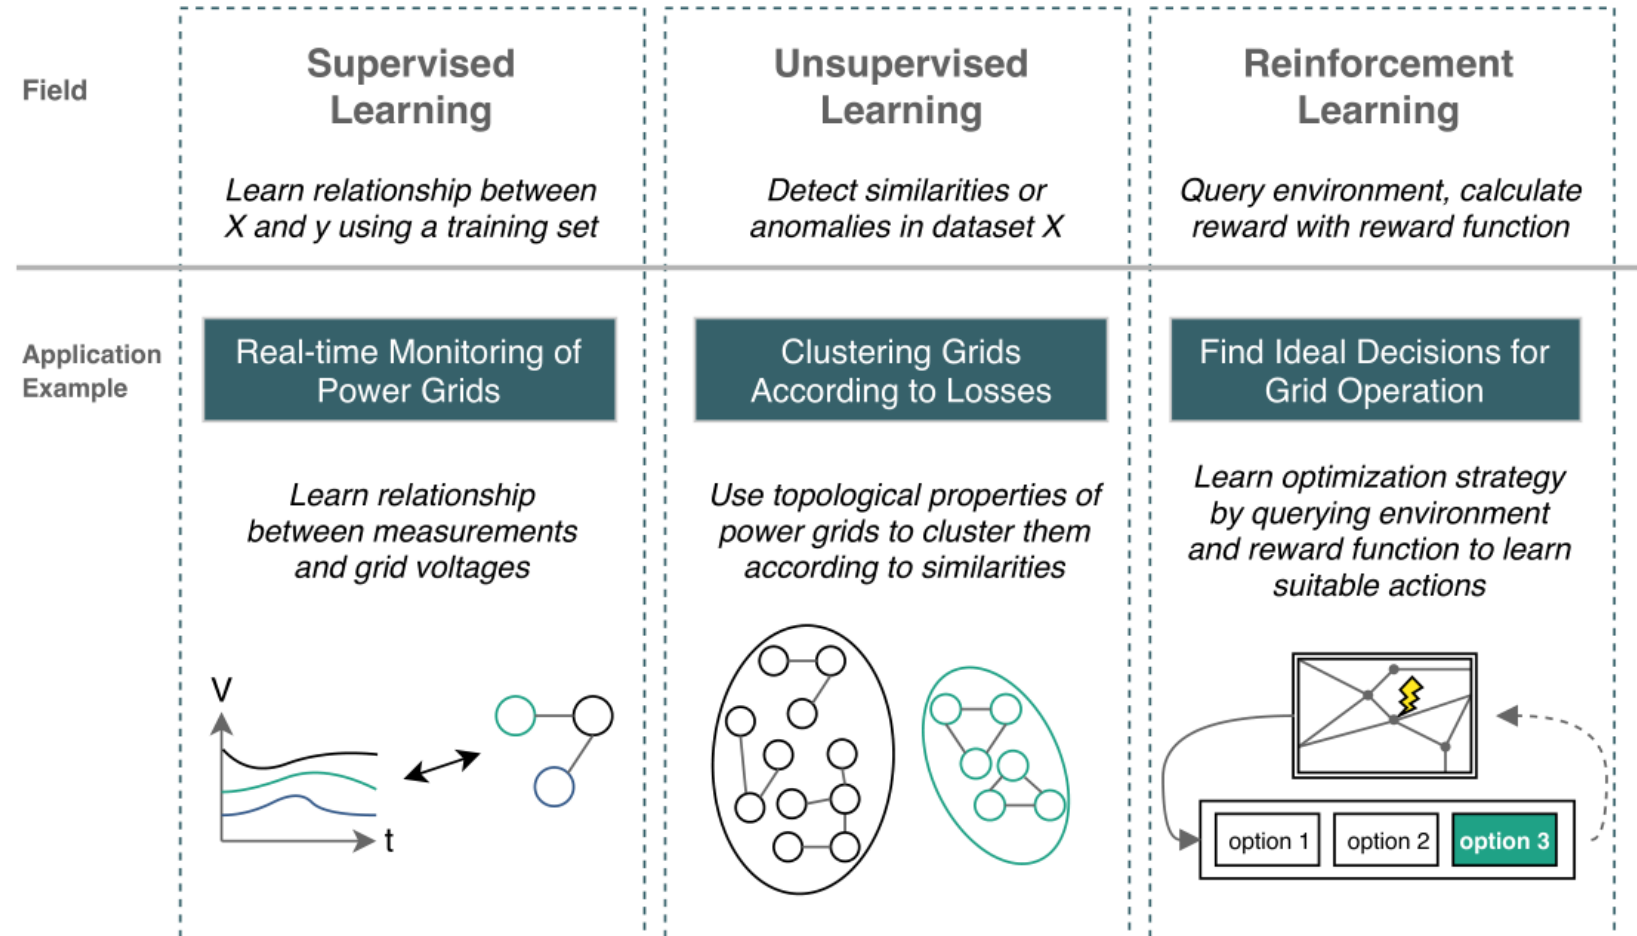


Source: <https://www.kdnuggets.com/2020/01/stock-market-forecasting-time-series-analysis.html>

# Verschiedene Arten des Lernens

- Unterschiedliche Aufgaben erfordern verschiedene Arten des „Lernens“

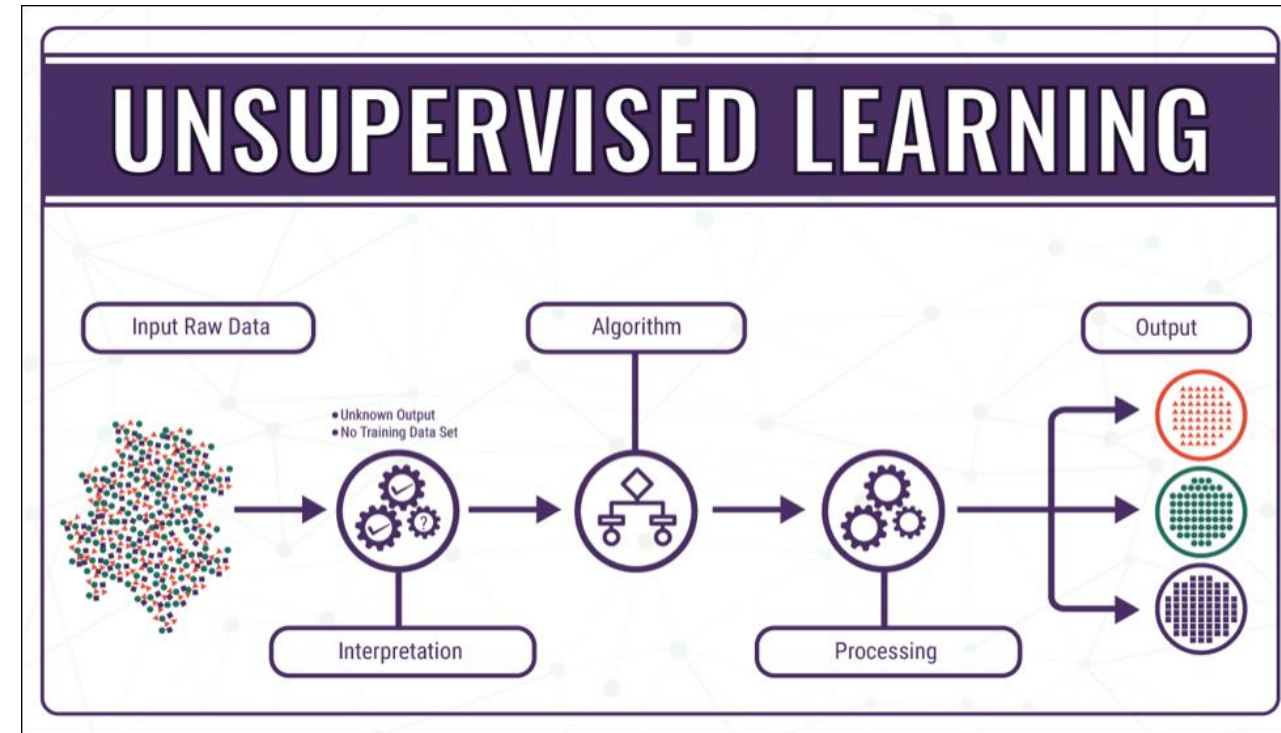
1. Überwachtes Lernen
2. Unüberwachtes Lernen
3. Selbstüberwachtes Lernen



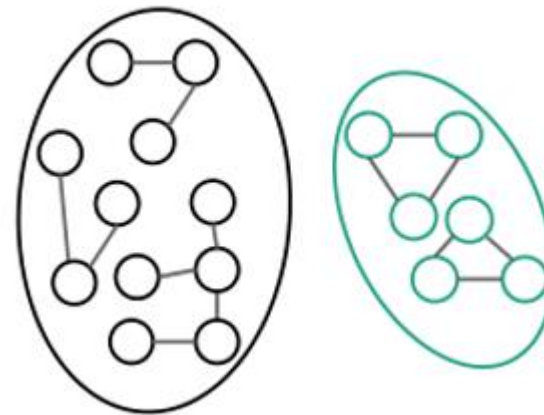
Source: Menke et al  
(<https://www.springer.com/gp/book/9783030427252>)

# Unüberwachtes Lernen

- Fehlende Beziehung zwischen **Eingaben** zu vorhandenen **Ausgaben**
  - → **Wie sieht die Korrelation aus?**
- Nutzung von Unterscheidungsmerkmalen in den Eingangsdaten → Suche nach Strukturen
- Beispiel: Gruppierungen
  - Aufteilung von potenziellen Kundengruppen
  - Einordnung von Stromnetzen nach bestimmten **topologischen Merkmalen** (z.B. Vermaschungsgrad, Netzverluste, Kurzschlusskapazität)



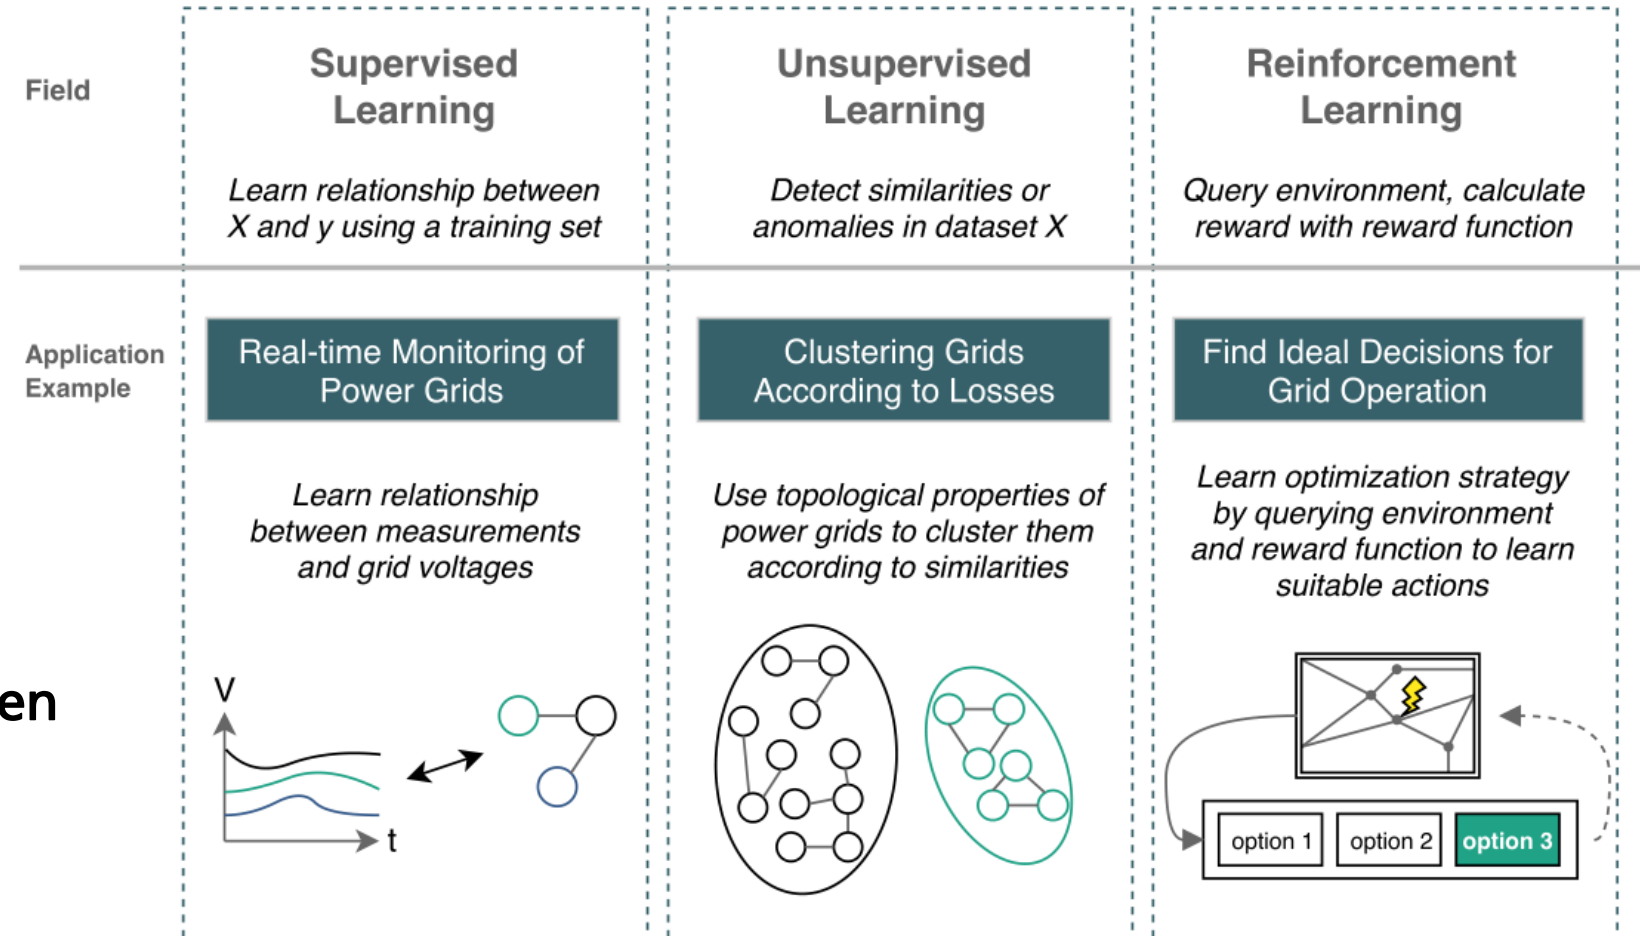
[technative.io/why-unsupervised-machine-learning-is-the-future-of-cybersecurity/](https://technative.io/why-unsupervised-machine-learning-is-the-future-of-cybersecurity/)



# Verschiedene Arten des Lernens

- Unterschiedliche Aufgaben erfordern verschiedene Arten des „Lernens“

1. Überwachtes Lernen
2. Unüberwachtes Lernen
3. Selbstüberwachtes Lernen




Source: Menke et al  
<https://www.springer.com/gp/book/9783030427252>

# Selbstüberwachtes Lernen

- Ein „Agent“ (z.B. KNN) lernt durch Interaktion mit seiner Umgebung
- Aktionen und resultierende Zustände werden nach vorher festgelegten Kriterien beurteilt
- „besserer“ Zustand → Belohnung
- „schlechterer“ Zustand → Bestrafung
- Ergebnis ist NICHT die einzelne Aktion, sondern der Endzustand und der Weg dahin
- Nicht angewiesen auf vorhandenen statischen Datensatz, sondern kann in dynamischen Umgebungen angewendet werden
- Bsp: Alpha-GO, Selbststeuerndes Fahren, etc...



Quelle: Fraunhofer IPA




<https://de.mathworks.com/discovery/reinforcement-learning.html>


# Überwachtes vs. Unüberwachtes Lernen vs. Selbstüberwachtes Lernen

## machine learning


unsupervised learning



supervised learning



reinforcement learning



<https://de.mathworks.com/discovery/reinforcement-learning.html>

- Finden und Erkennen von Strukturen und Klassifikationen

- Einhalten von Klassifikationen und Strukturen / Folgen von Regeln

- Finden von optimalen „Wegen“ in unbekanntem Umgebungen

- Kombination von mehreren Methoden möglich:
  - Bsp. Bild- oder Zeichenerkennung

---


# NEURONALE NETZE

---



# Künstliche Neuronale Netze - KNN


- KNN sind eine Art von Modellen, die beim maschinellen Lernen verwendet werden.
- KNN bestehen aus einer Eingabeschicht, einer oder mehreren versteckten Schichten und einer Ausgabeschicht
- Jede Schicht besteht aus einer Reihe verschiedener Neuronen, die Informationen empfangen, verarbeiten und mit nachfolgenden Neuronen verbunden sind
- Inspiriert von biologischen Neuronen im Gehirn, aber sehr einfaches Modell




Source: Cburnett on Wikimedia Commons

# Künstliche Neuronale Netze – Model eines einfachen Neurons

## Biologisches Neuron:



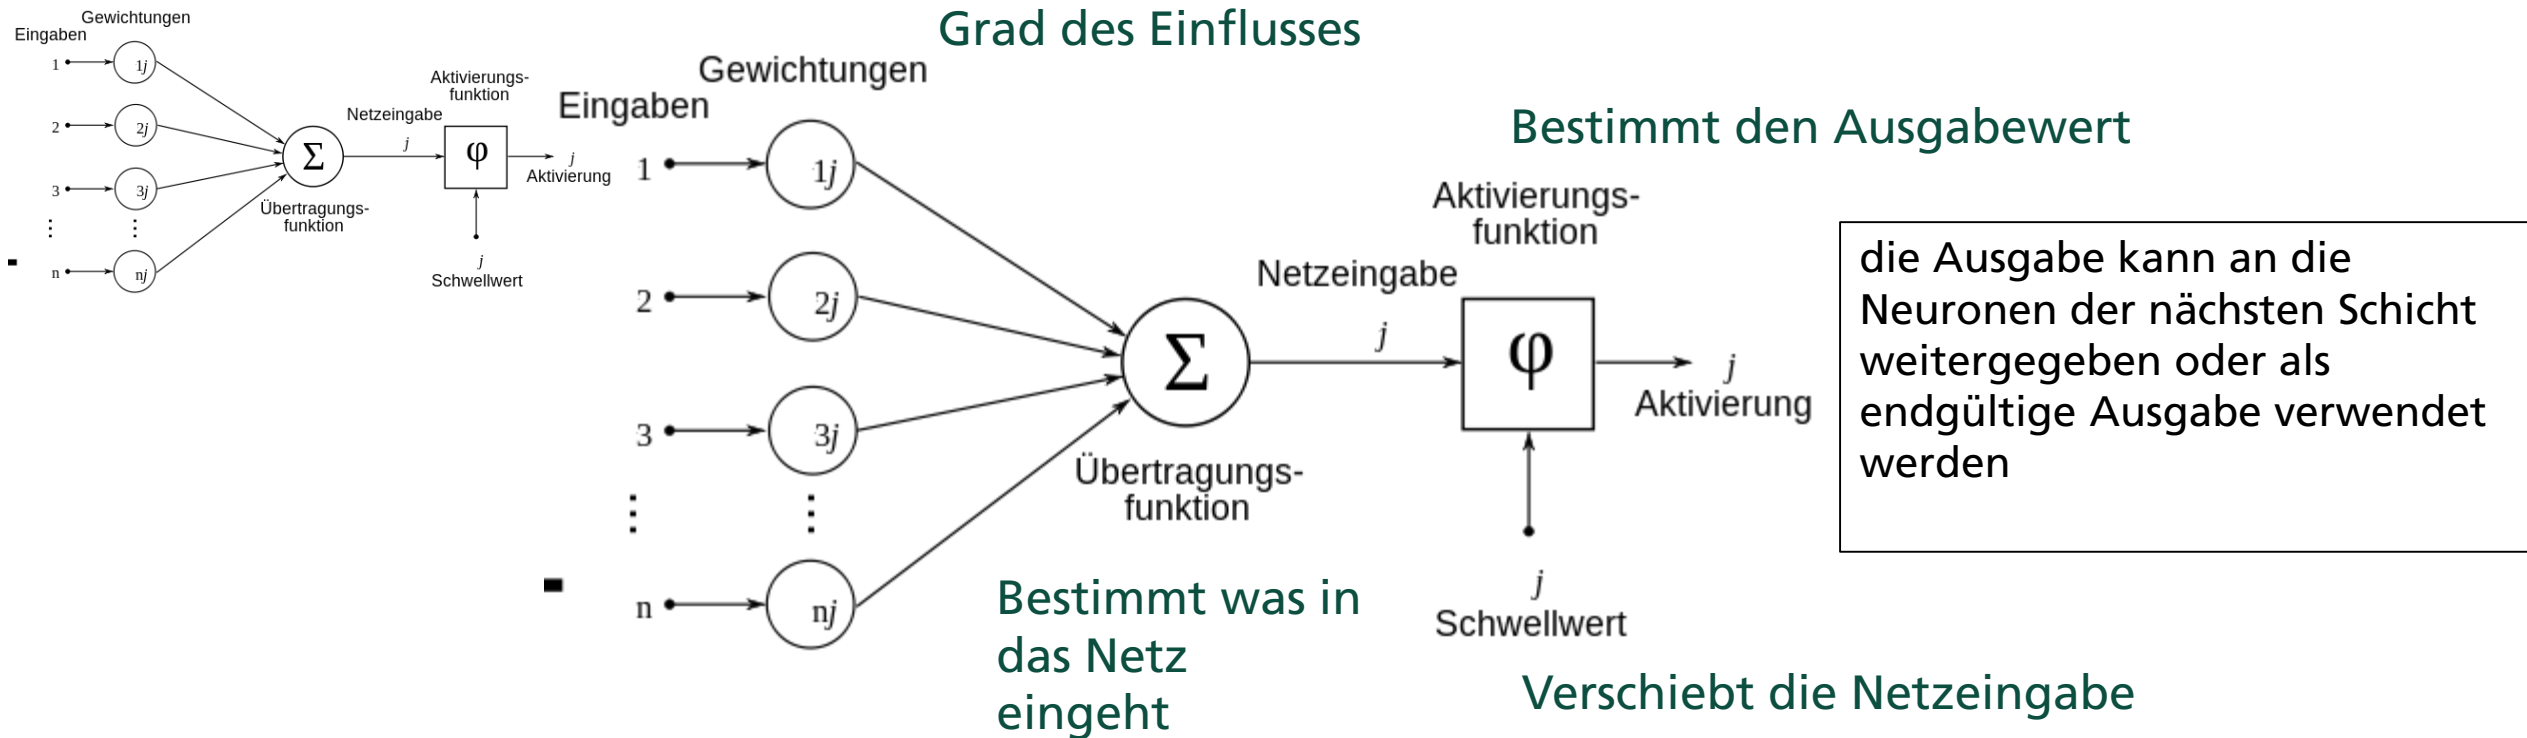
## Häufig verwendetes mathematische Modell (stark vereinfacht)



Source: CS231n Convolutional Neural Networks for Visual Recognition, Stanford University


# Künstliche Neuronale Netze – Model eines einfachen neuronalen Netzes

- Mathematisch gesehen sind KNN eine **Reihe** von nichtlinearen mathematischen Funktionen
- Jedes Neuron erhält unterschiedlich **gewichtete Eingaben**, die summiert und durch eine nichtlineare Aktivierungsfunktion geleitet werden




# Übersicht über weitere neuronale Netze


- Feed Forward Neural Networks / Fully Connected Neural Networks




- Convolutional Neural Networks (CNN): Bild-/Spracherkennung durch Faltung




- Recurrent Neural Networks (RNN): Sequenzen und LSTM



- Autoencoder: Unüberwachtes Lernen ohne Zieldaten



- Transformer: Texterfassung durch Attention-Layer



<https://divis.io/2020/03/arten-von-kuenstlichen-neuronalen-netzen/#gref>

---

# AKTUELLE KI-ANWENDUNGEN IM BEREICH DER ENERGIETECHNIK


---

# ENERGIEPROGNOSEN

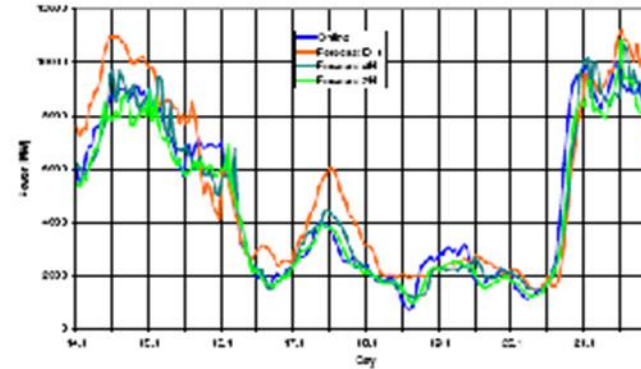
**Representative wind farms**



**Numerical weather model**



**Wind power prediction for TSO control zone**



Online value of the actual produced power of the wind farm

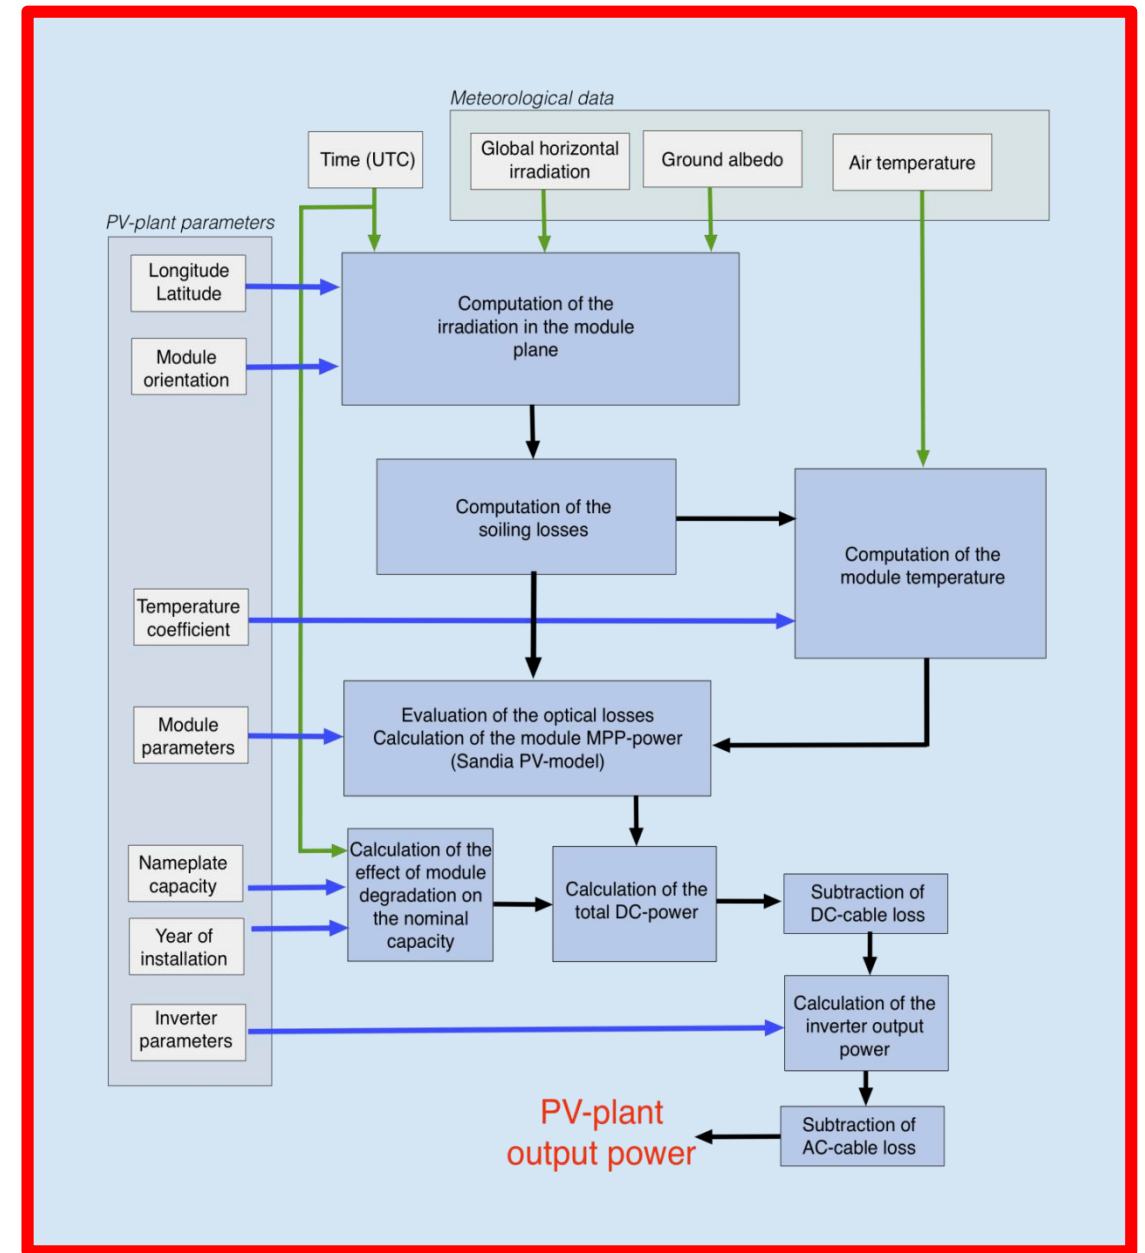
Weather prediction for the site of the repr. wind farm

Wind power prediction for representative wind farms

Extrapolation on TSO control zone

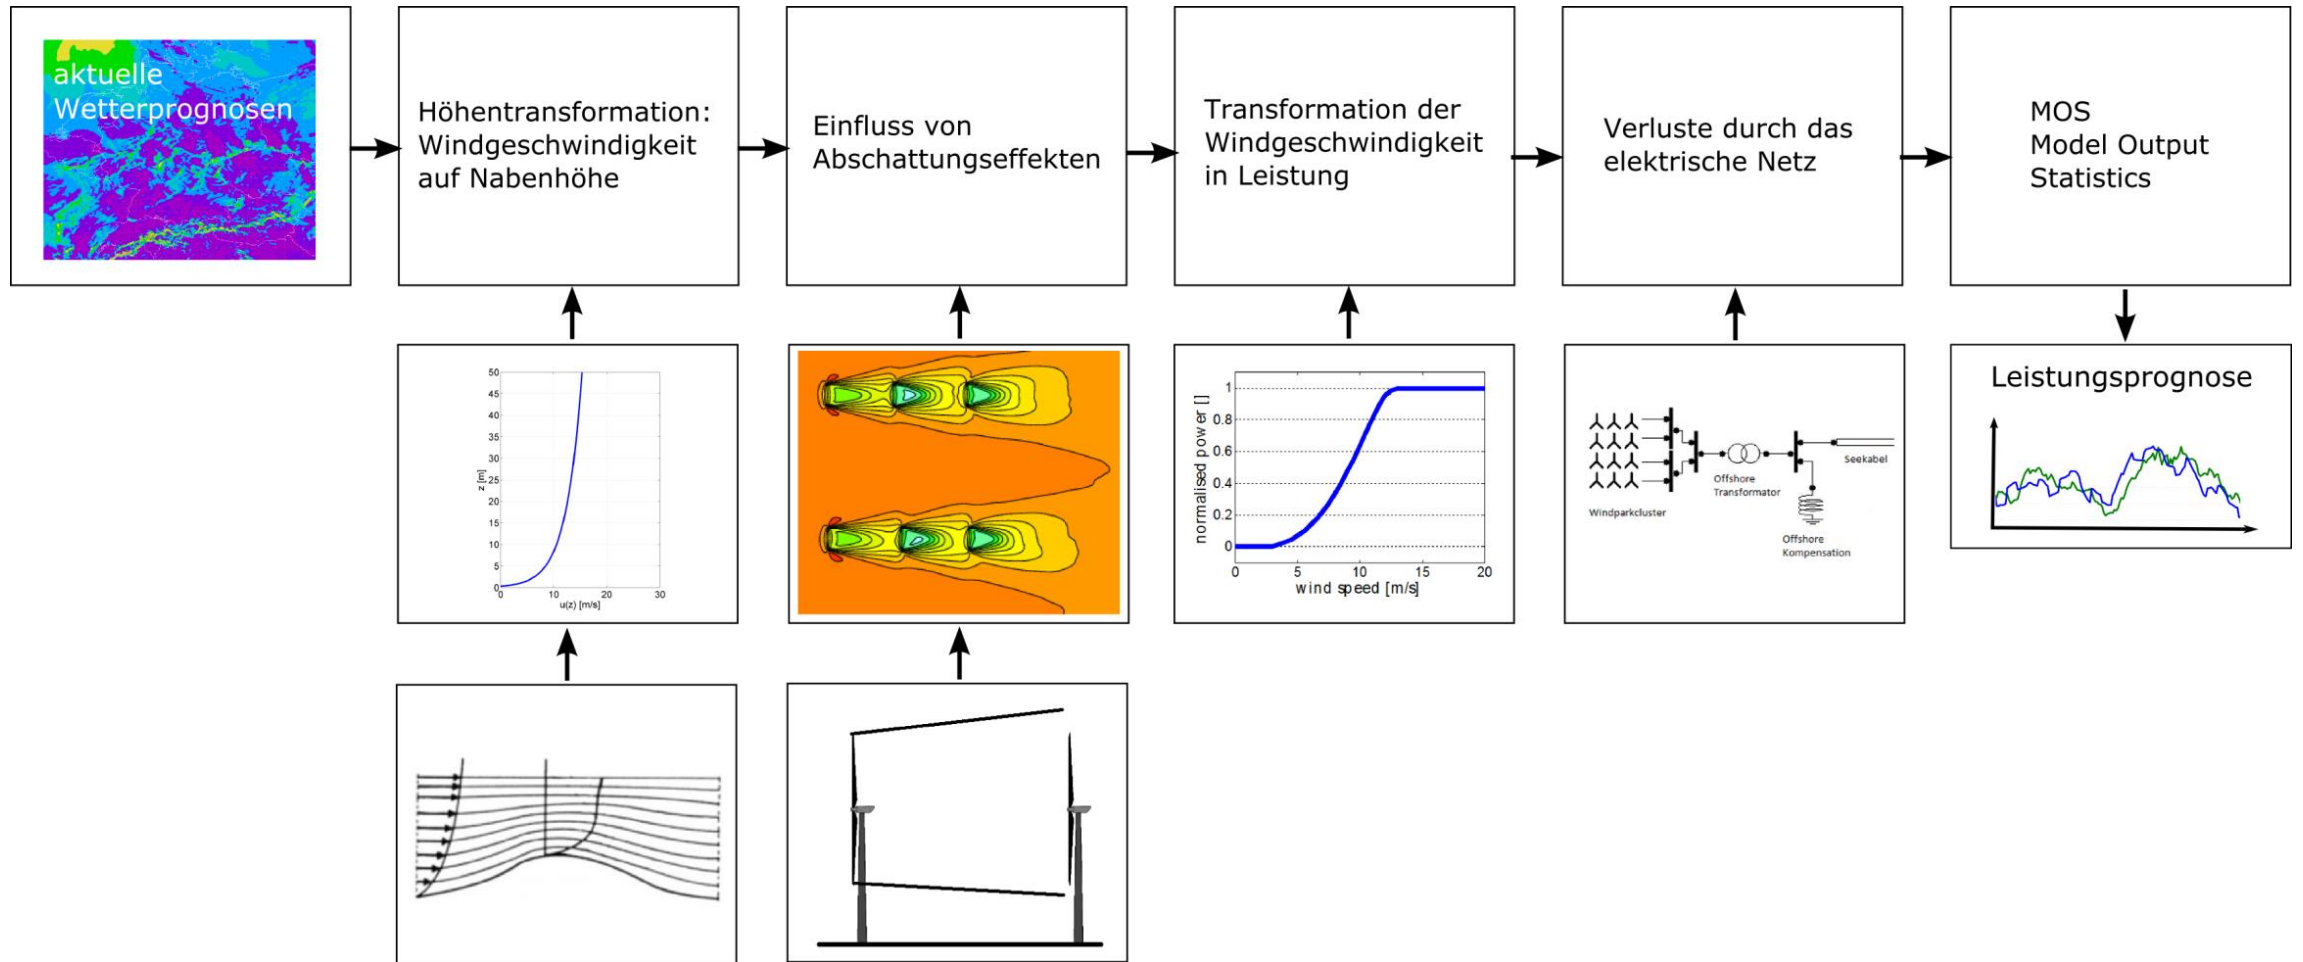
# Physikalische Modelle

- Modelle einzelner Anlagen oder ganzer Parks
- Verschiedene Modelle für Windanlagen und PV-Anlagen öffentlich vorhanden
- Inputdaten sind z.B. für PV Anlagen u.a.:
  - Solare Einstrahlung
  - Temperatur in 2m Höhe
  - Neigungswinkel
  - Orientierung
  - PV-Modul Verluste
  - Optische Verluste (z.B. Staub, Verschattung)
  - Abnutzung / Alterung
  - Temperaturabhängigkeit
  - ...





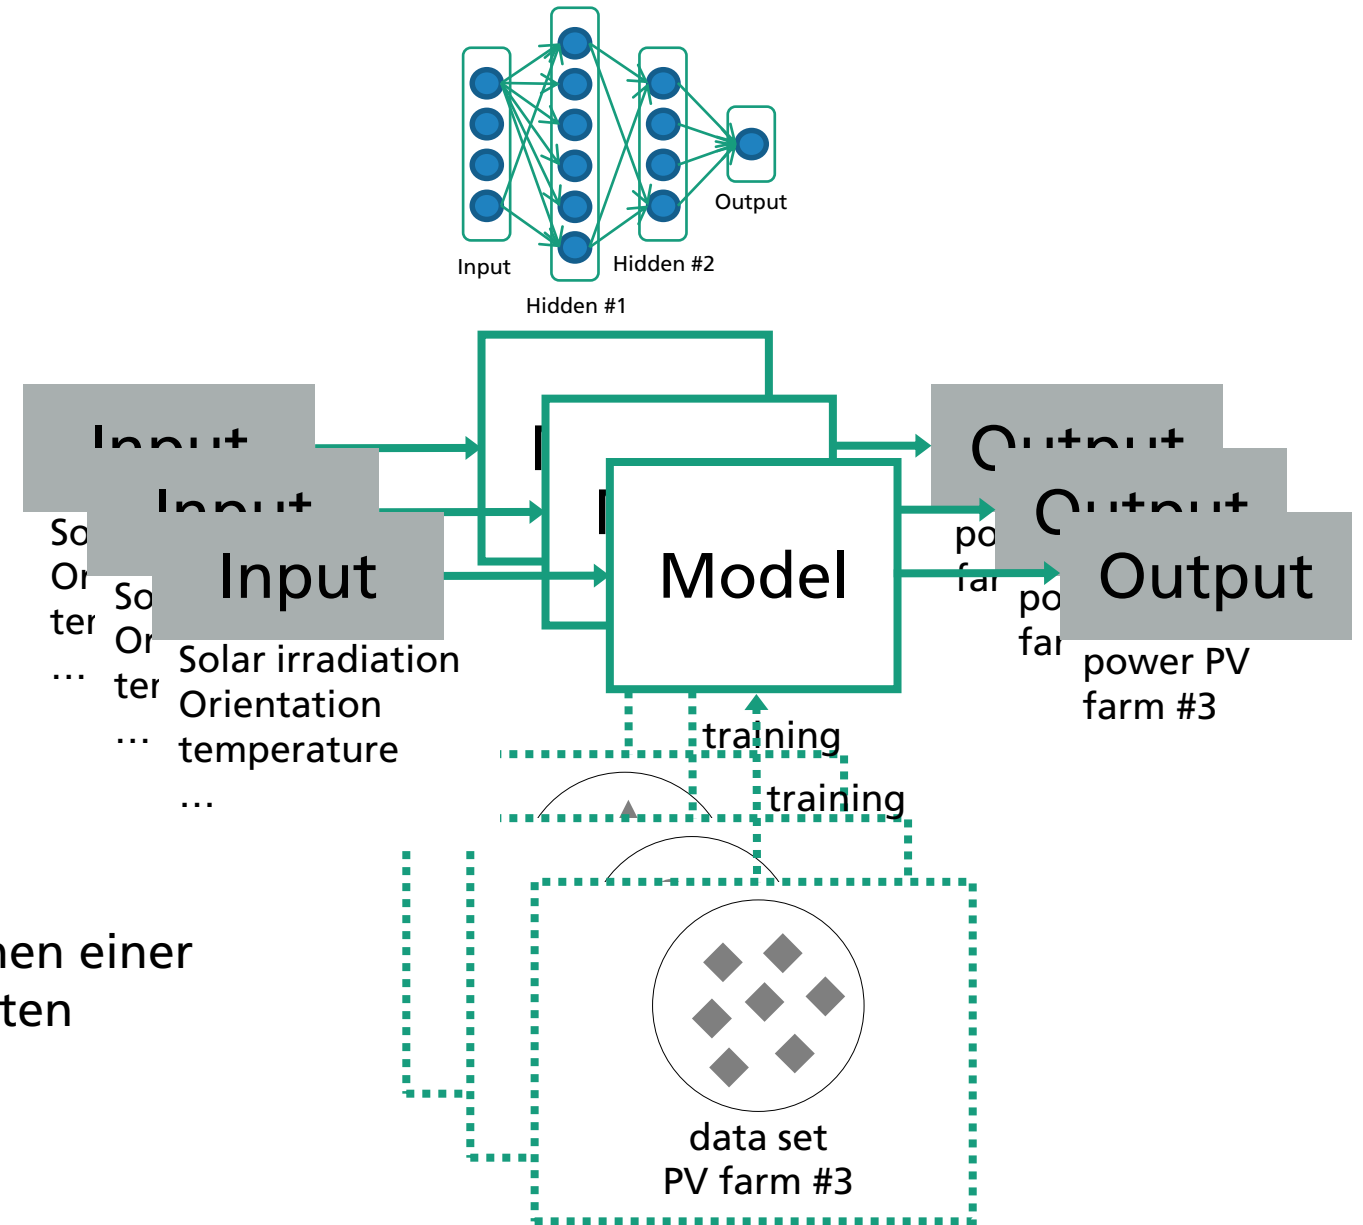
# Folgetagsprognose mit einem „physikalischen“ Modell



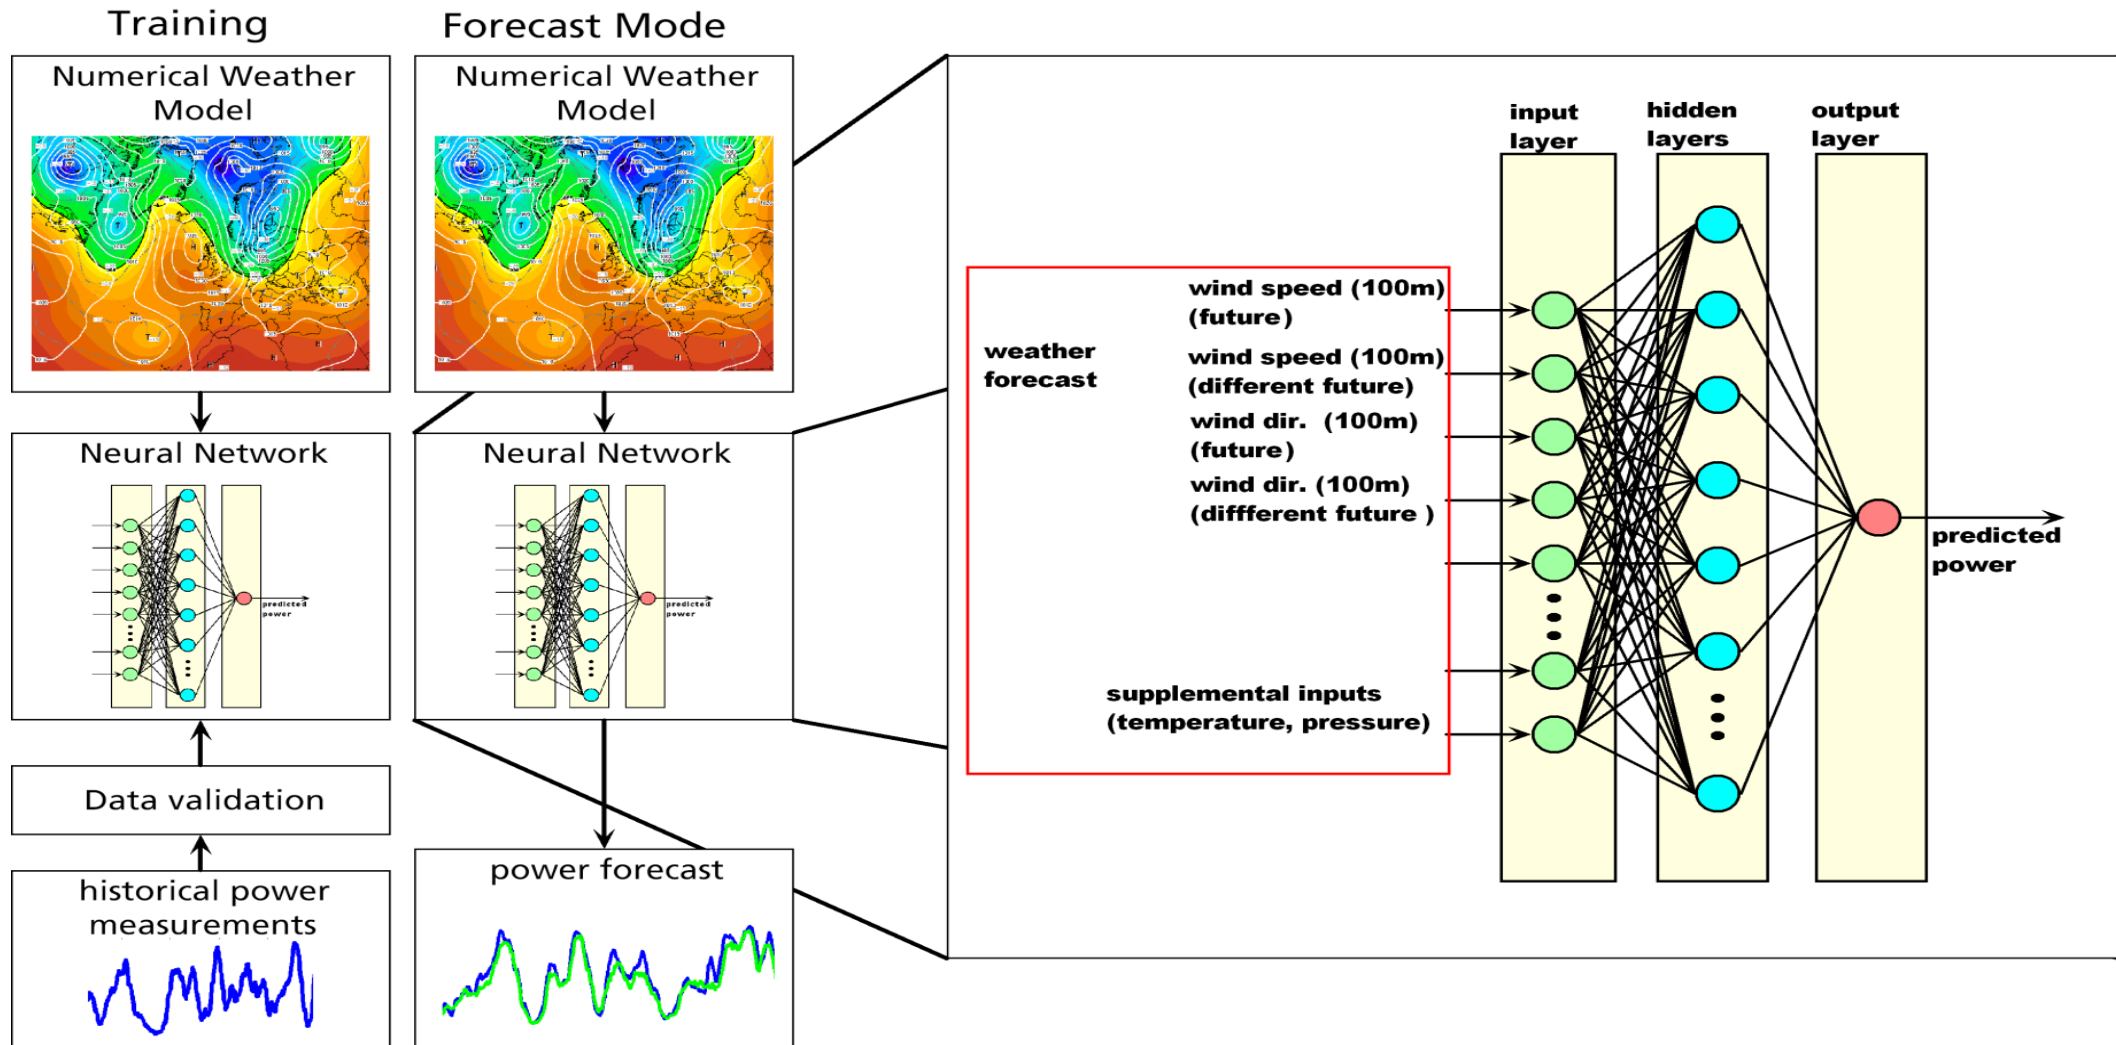
# Modelle durch Maschinelles Lernen

## Künstliches Neuronales Netz

- Eingabeschicht: jedes Merkmal
- Gewichtete Summe der Einheiten der vorherigen Schicht
- Gewichtung zur Minimierung des mittleren quadratischen Fehlers
- Das KNN „lernt“ durch Korrelation von Inputparametern und historischen Zeitreihen einer bestimmten Anlage das spezifische Verhalten



# Day-Ahead Leistungsprognose mit einem statistischen Modell



# Vor- und Nachteile der Vorhersagemethoden

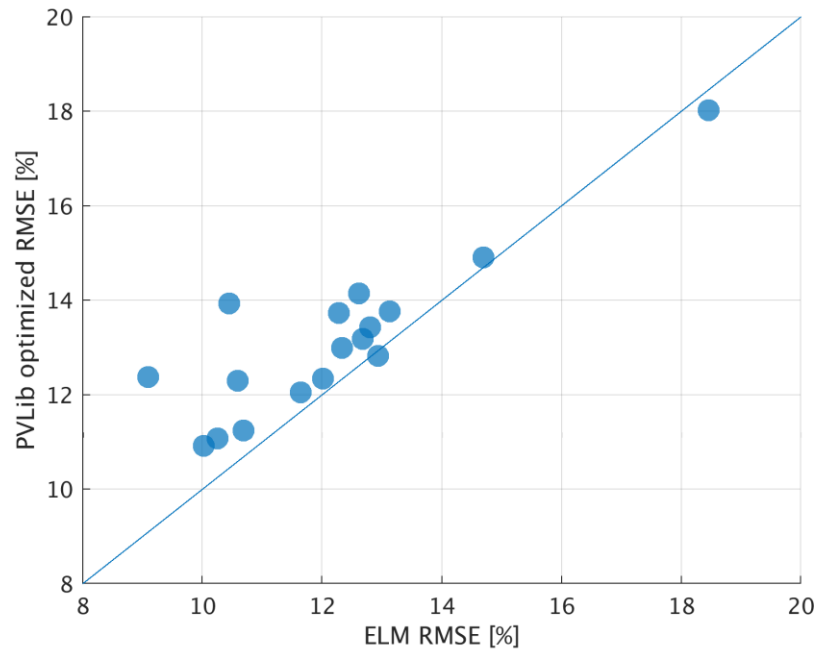
## Statistische und KI-Methoden

- + keine detaillierte Kenntnis der Physik notwendig
- + schnelle Berechnung
- Abhängig von qualitativ hochwertigen historischen Daten
- Unsicher bei neuen oder seltenen Situationen

## Physikalische Methoden

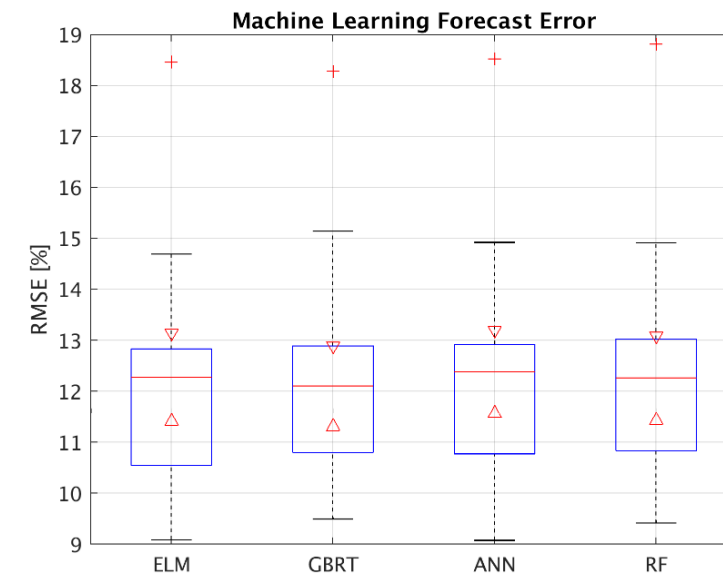
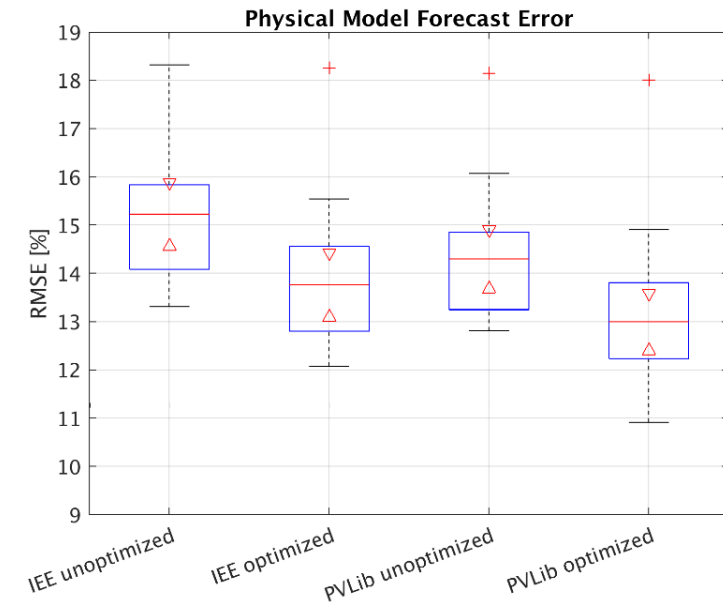
- + Die Qualität von gemessenen historischen Daten ist zweitrangig
- Detaillierte Informationen des Windparks und der Umgebung werden benötigt.
- Großer Aufwand das Modell für den Windpark aufzusetzen

# Vergleich: Physikalisches Modell vs. KNN Modell



- Mittlerer Fehler ist für stat. Modelle < phys. Modelle


→ Maschinell erlernte Modelle erzeugen bessere Prognosen wenn Messdaten vorhanden sind.



# NeuRaSat – Einstrahlungsprognose mit Satellitendaten und KI


## Satellitendaten:

- Bilder der letzten Stunde
- IR-Kanäle, Vis-Kanäle




## GIS-Daten:

- Gelände
- Landbedeckung
- Lon und Lat



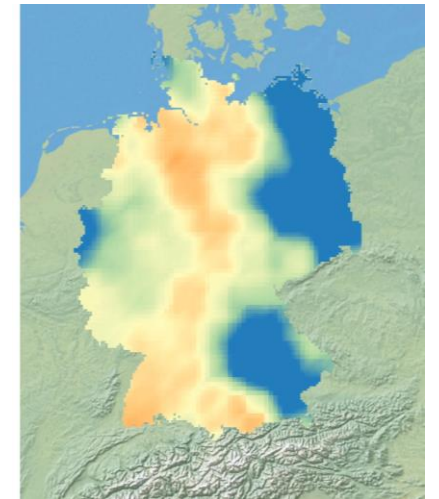
## Output aus Optical Flow



## Zusätzliche Inputs



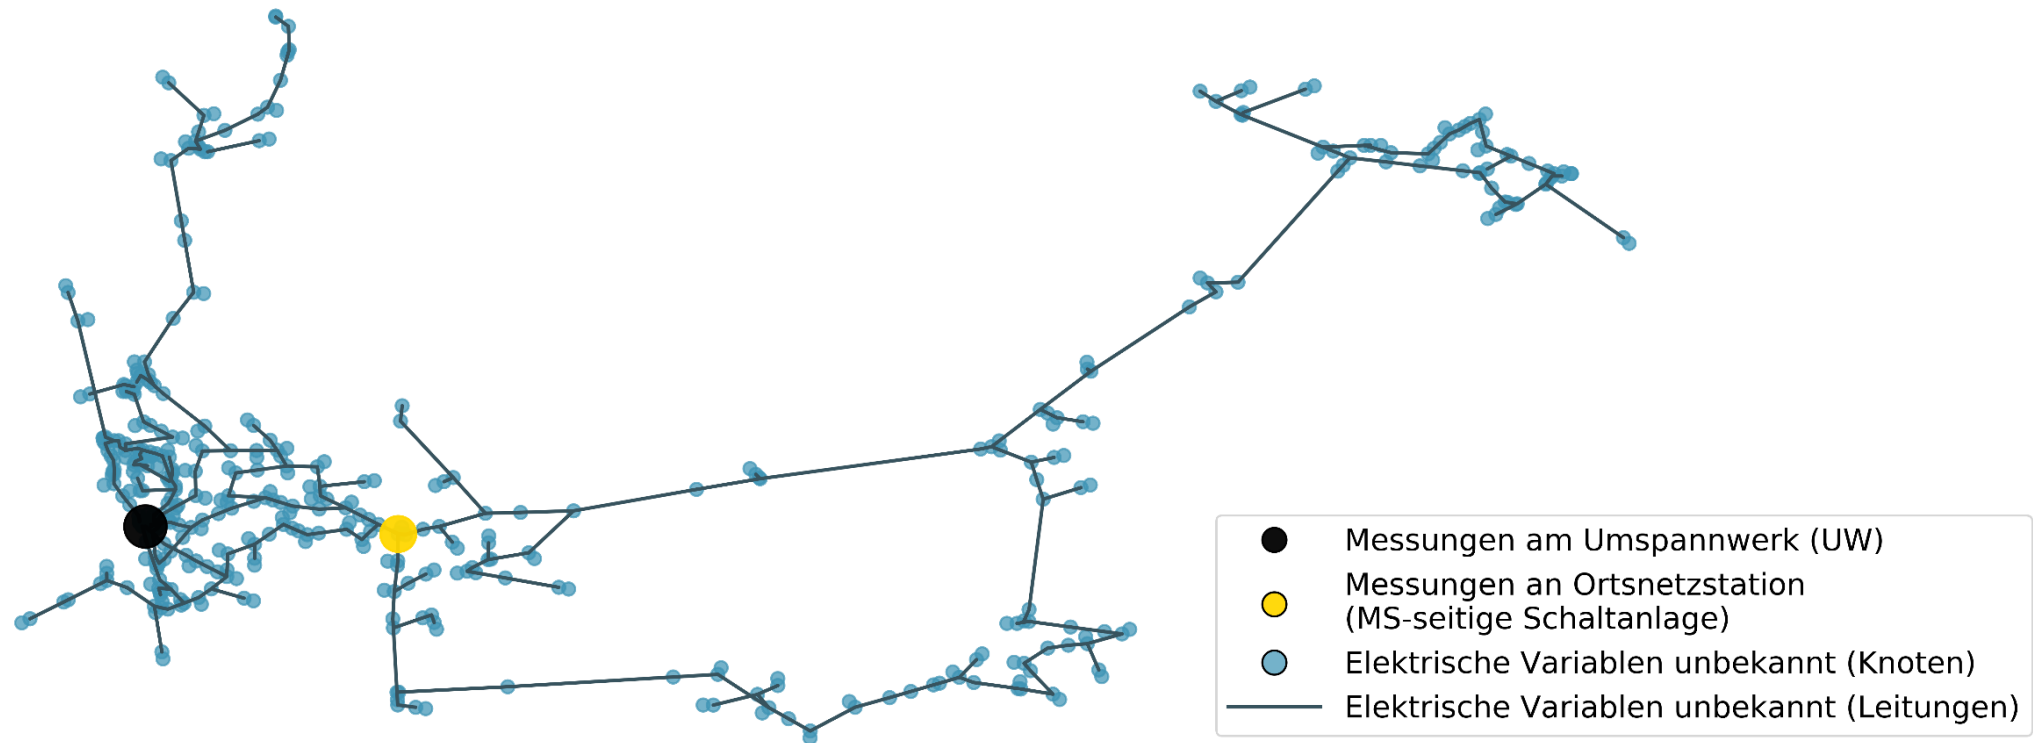
Kombination von KI-Methoden zur Modellierung der räumlichen und zeitlichen Zusammenhänge



Räumlich aufgelöste Vorhersage der Einstrahlung für die nächsten Stunden

Kontakt: Dr. Lukas Pauscher ([lukas.pauscher@iee.fraunhofer.de](mailto:lukas.pauscher@iee.fraunhofer.de))

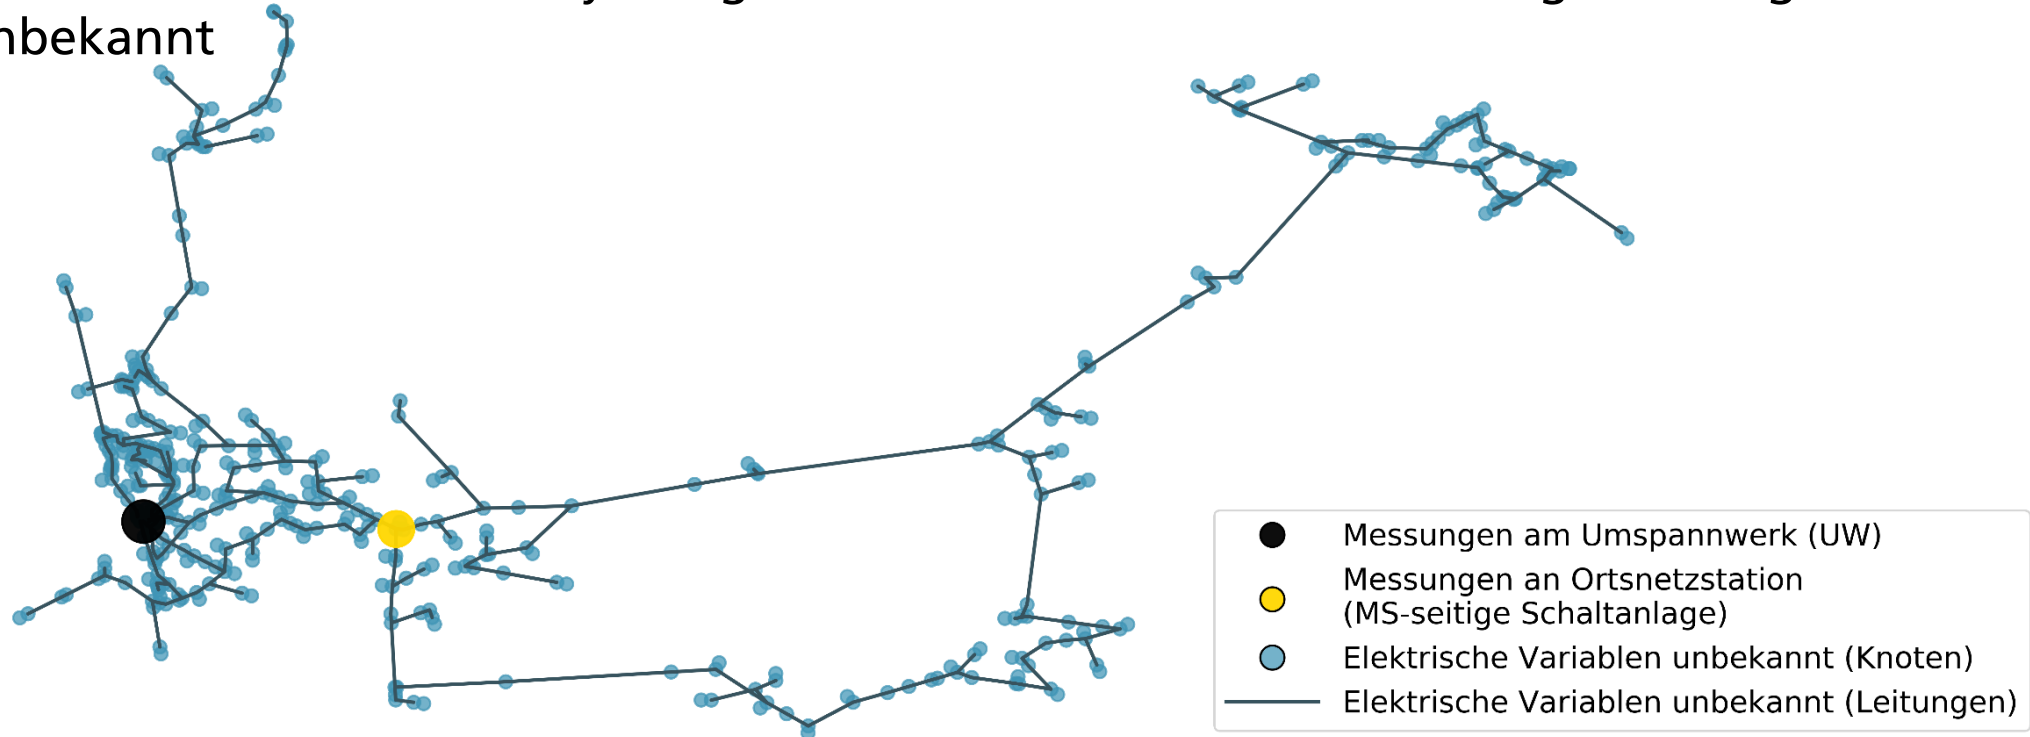
# ZUSTANDSBESTIMMUNG IN DER MITTELSPANNUNGSEBENE MIT KÜNSTLICHEN NEURONALEN NETZEN (KNN-SE)





# Hintergrund und Motivation

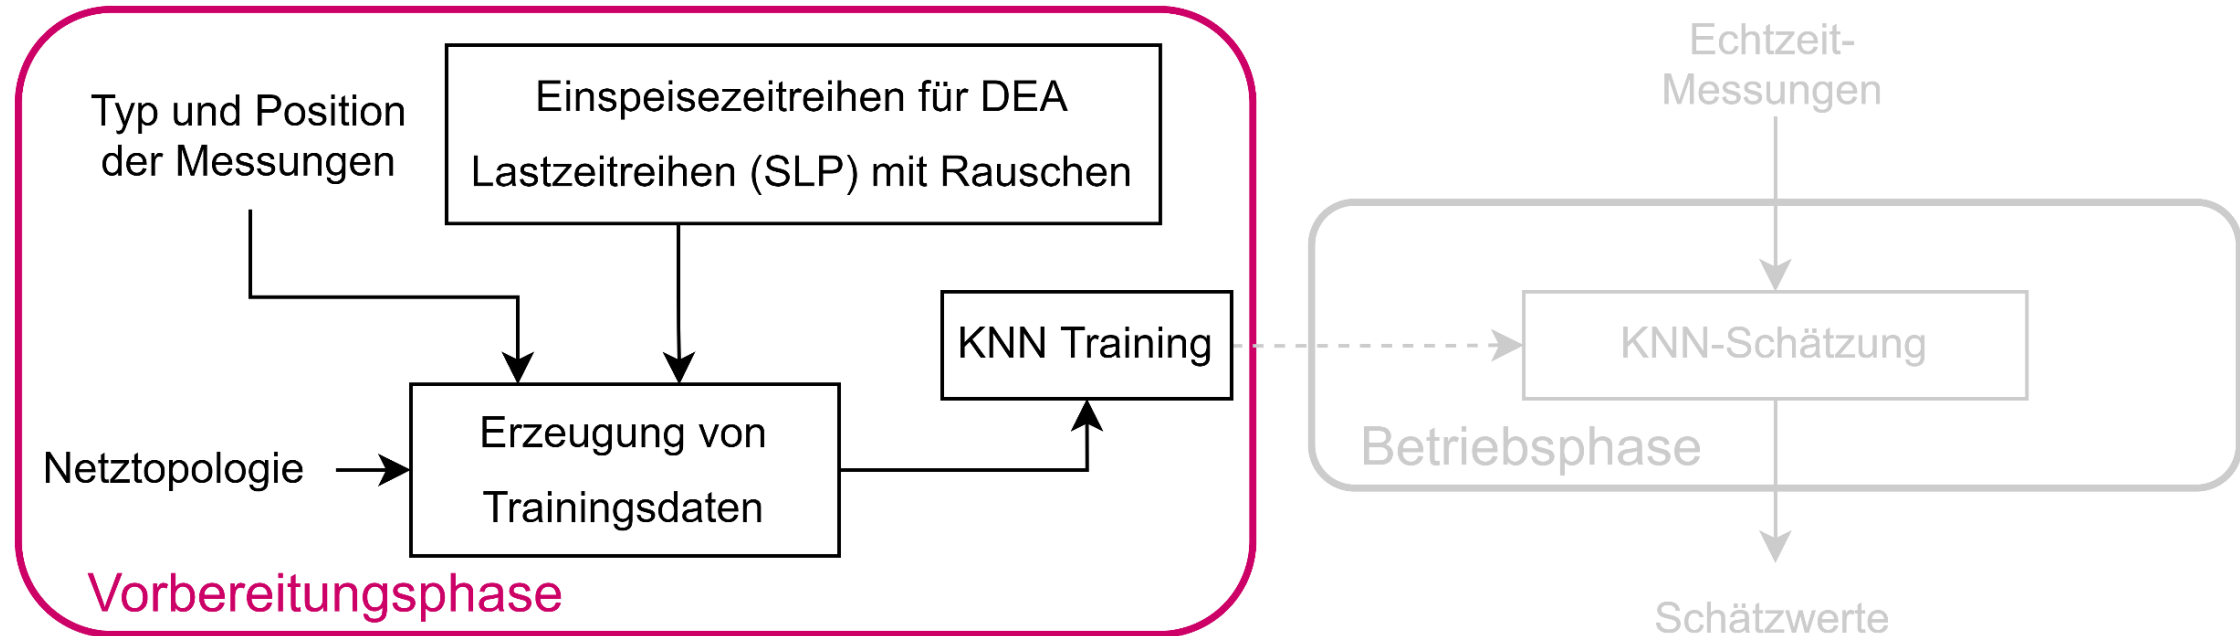
- In der Regel sind nur die HS/MS-Umspannstationen vollständig ausgemessen
- Weitere Messungen können sich vereinzelt an MS/NS-Ortsnetzstationen befinden
- Der aktuelle Zustand der Systemgrößen ist mit Ausnahme der wenigen verfügbaren Messwerte unbekannt



SE - Methoden sollen sicherheitsrelevante Variablen schätzen und somit **Transparenz und Sichtbarkeit** erzeugen

# KNN-SE: Grundlagen und Methodik

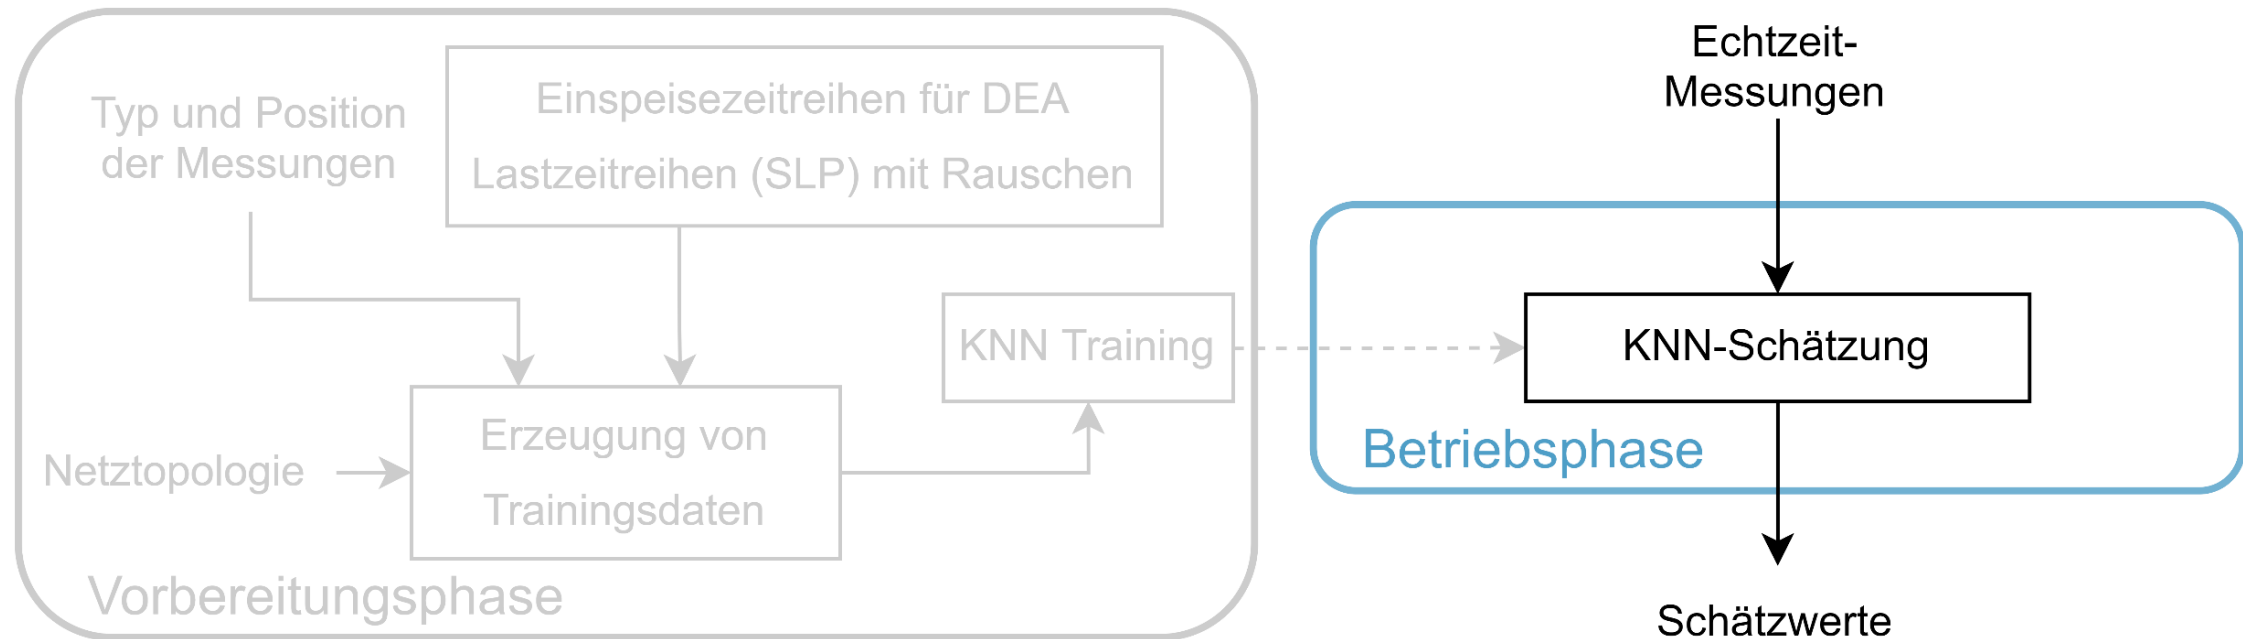
In der Betriebsphase schätzt das trainierte KNN: Knotenspannungen  $U_k$ , Stromfluss  $I_l$ , Blindleistungsfluss  $Q_l$ , und Wirkleistungsfluss  $P_l$  für die Knoten  $K$  bzw. Leitungen  $l$



In der **Vorbereitungsphase** wird eine möglichst hohe Anzahl an Netzzuständen bei angemessenem Rechenaufwand abgebildet. Hierbei werden die Positionen aller Messstellen sowie vorhandenes Messrauschen berücksichtigt.

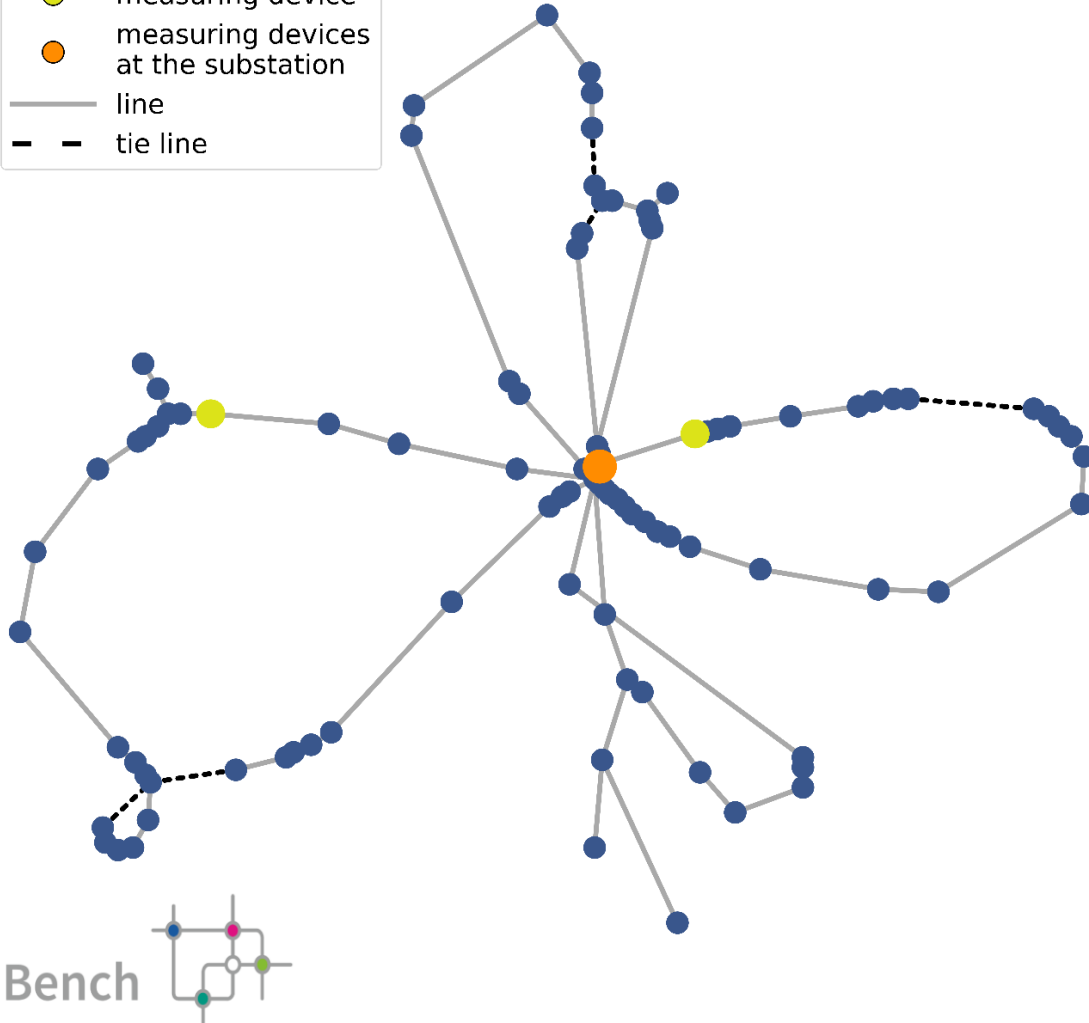

# KNN-SE: Grundlagen und Methodik

In der **Betriebsphase** schätzt das trainierte KNN: Knotenspannungen  $U_k$ , Stromfluss  $I_l$ , Blindleistungsfluss  $Q_l$ , und Wirkleistungsfluss  $P_l$  für die Knoten  $K$  bzw. Leitungen  $l$

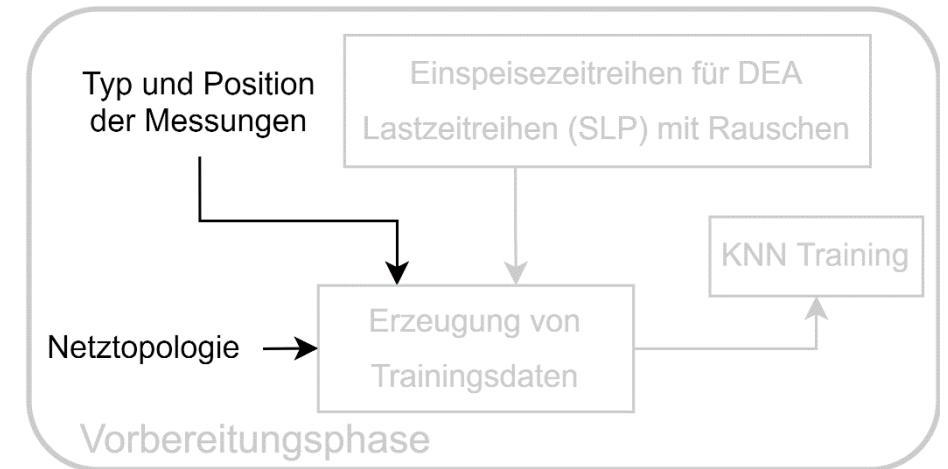


In der Vorbereitungsphase wird eine möglichst hohe Anzahl an Netzzuständen bei angemessenem Rechenaufwand abgebildet. Hierbei werden die Positionen aller Messstellen sowie vorhandenes Messrauschen berücksichtigt.

# KNN-SE: Grundlagen und Methodik



SimBench



20 kV Mittelspannungsnetz (rural):

- Offene Ringstruktur
- Entwicklungsszenarien für EE-Zubau
- 97 Knoten, 101 Leitungen (118.1km)
- 96 Lasten, 102 statische Generatoren
- 32 Messungen

# Trainingsdaten: Einspeise- und Lastzeitreihen

## Einspeisezeitreihen

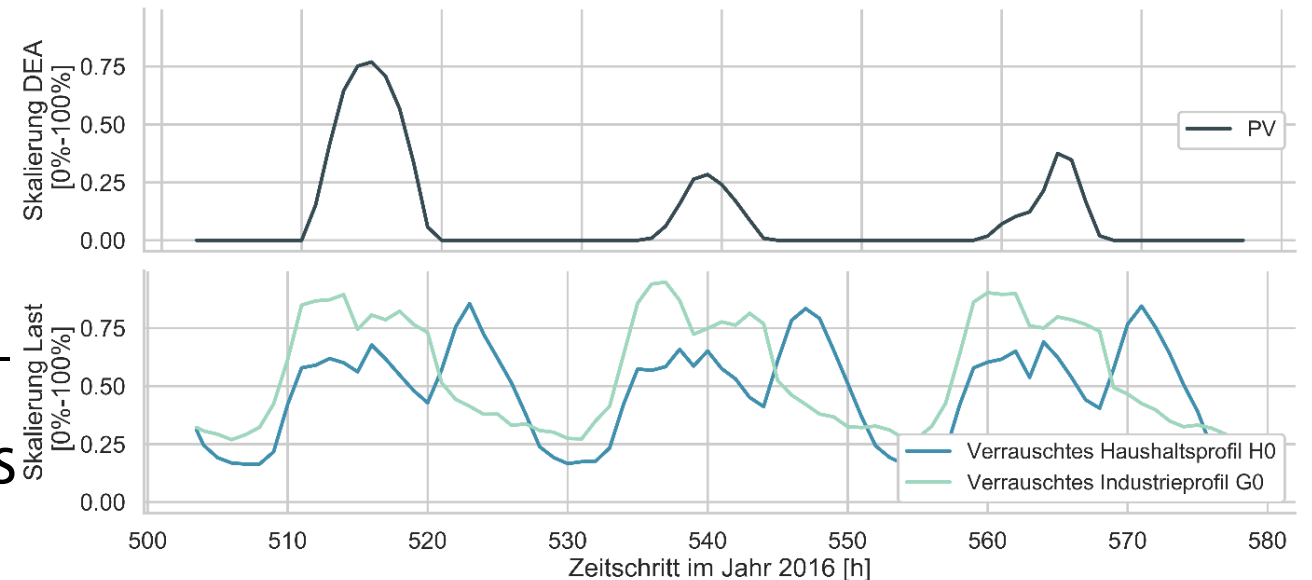
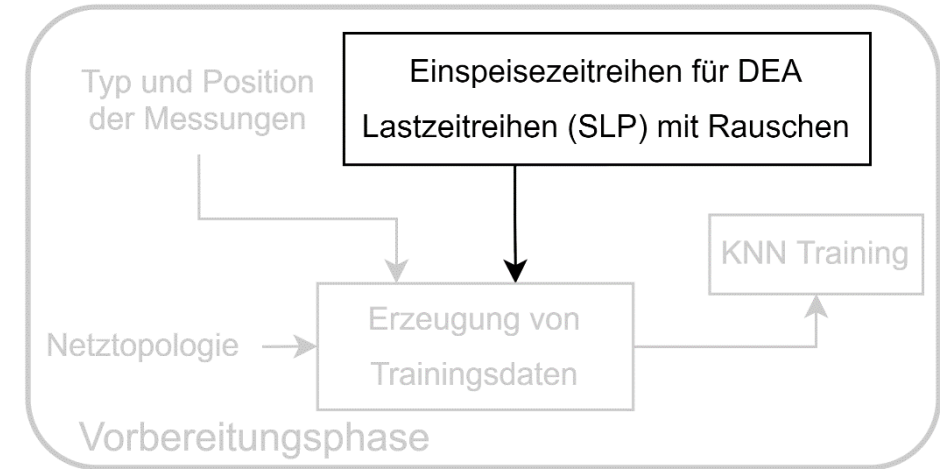
- Photovoltaikanlagen, Windkraftanlagen: Erstellung mittels renewables.ninja [3]
- Verwendung realer Einspeisezeitreihen
- Wasserkraftanlagen: Durchgängiger Betrieb bei Nennleistung

## Lastzeitreihen:

- Verrauschte Standardlastprofile:
  - Standardlastprofile für Haushalte (SLP-)
  - Standardlastprofile für Gewerbe (z.B. S

Exemplarische Zeitreihe:


17520 Zeitschritte der ersten Jahreshälfte 2016 [15min Werte]



# Trainingsdaten: Szenarien



## Exemplarische „Szenarien“:

- Gruppierung von Lasten und Einspeisern: 9
- Skalierung von 0.0 – 1.0 in 0.5 Schritten: 3
- $3^9 = 19583$  Trainingsszenarien



20 kV Mittelspannungsnetz (rural):

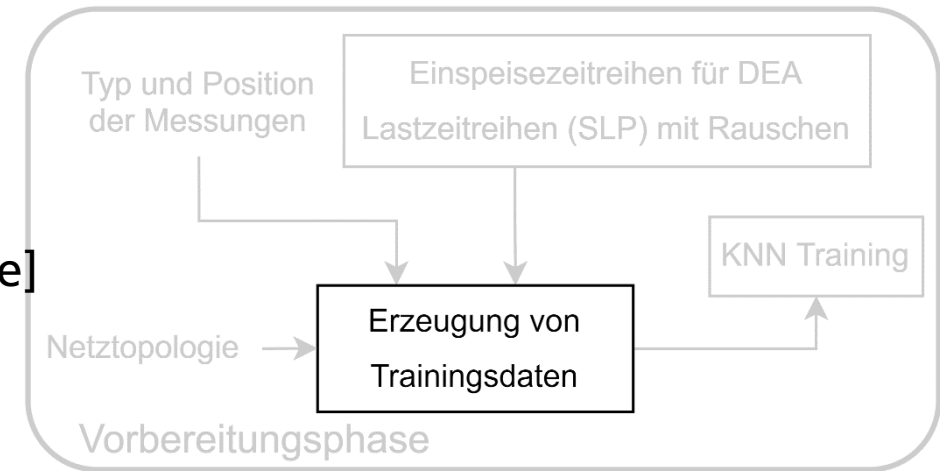
- Offene Ringstruktur
- 97 Knoten, 101 Leitungen (118.1km)
- 96 Lasten, 102 statische Generatoren



# KNN-SE: Grundlagen und Methodik

Exemplarische Trainingssets:

- 17520 Zeitschritte der ersten Jahreshälfte 2016 [15min Werte]
- 19583 Szenarien



(1) Skalierung der Last- und Erzeugungsanlagen für jeden Zeitschritt entsprechend der Zeitreihen



(1) Leistungsflussberechnung für den derzeitigen Zustand





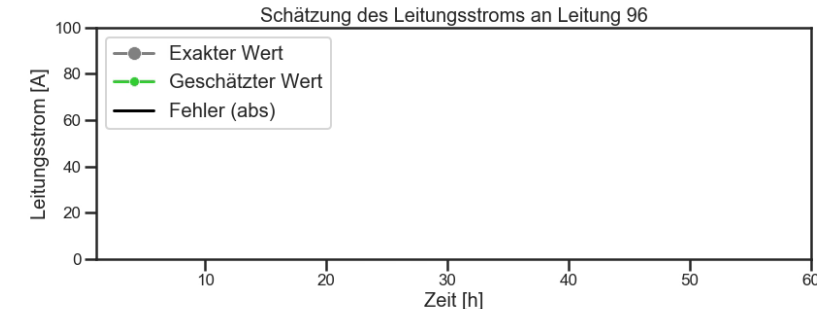




(1) Speichern der Ergebnisse  $P$ ,  $Q$ ,  $U$ ,  $I$ , und der zugehörigen Messwerte





# Zustandsbestimmung in Mittelspannungsnetzen - Beispielanimation






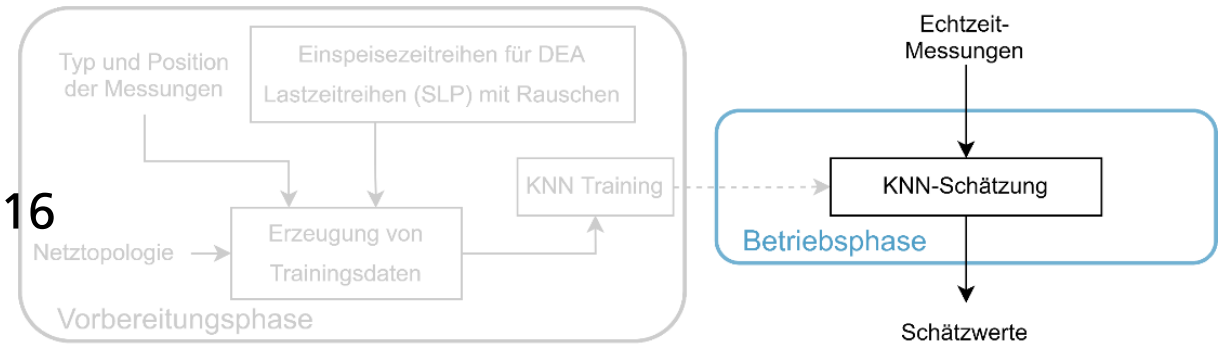
# KNN-SE: Schätzergebnisse

Trainingssets [15min Werte]:

- 17520 Zeitschritte der ersten Jahreshälfte 2016

Testdaten [15min Werte]:





- 17520 Zeitschritte der zweiten Jahreshälfte 2016



# ANN-Monitoring im Mittelspannungsnetz – Vergleich mit den Ergebnissen einer WLS Schätzung

WLS: Weighted Least Square Schätzung  
(mit 10% uniform noise auf Pseudomessungen)

ANN - Monitoring: Szenarien



# OPTIMIERUNG MIT HILFE VON KI

$$V_{\text{lower}} \leq V_b \leq V_{\text{upper}} \quad \forall b \in \{1, 2, \dots, n_{\text{buses}}\}$$

$$L_l \leq L_{\text{upper}} \quad \forall l \in \{1, 2, \dots, n_{\text{lines}}\}$$

$$L_t \leq L_{\text{upper}} \quad \forall t \in \{1, 2, \dots, n_{\text{transformers}}\}$$



$$L_{\text{constraints}} = s(100 \sum_{b=1}^{\text{buses}} \max(0, V_b - V_{\text{upper}}, V_{\text{lower}} - V_b) + \sum_{l=1}^{\text{lines}} \max(0, L_l - L_{\text{upper}}) + \sum_{t=1}^{\text{transf.}} \max(0, L_t - L_{\text{upper}}))$$



$$I = L_{\text{constraints}} + \sum_{b=1}^{\text{buses}} P_{\text{inj}_b}$$

# KI-OPF

- Ansatz: Selbstüberwachtes Lernen (+Kombination mit überwachtem Lernen)
- Ziel: Lösen des klassischen OPF Problems sowie Flexibilitätsbestimmung für Verteilnetze mittels Reinforcement Learning (RL)
- Verlustminimierung/Flexibilitätsbestimmung
- Einhaltung der Netznebenbedingungen
- Verlustfunktion:
  - Ziel (Verlustminimierung/Flexibilität) + Strafterm für Randbedingungsverletzung (Spannung und Auslastung)

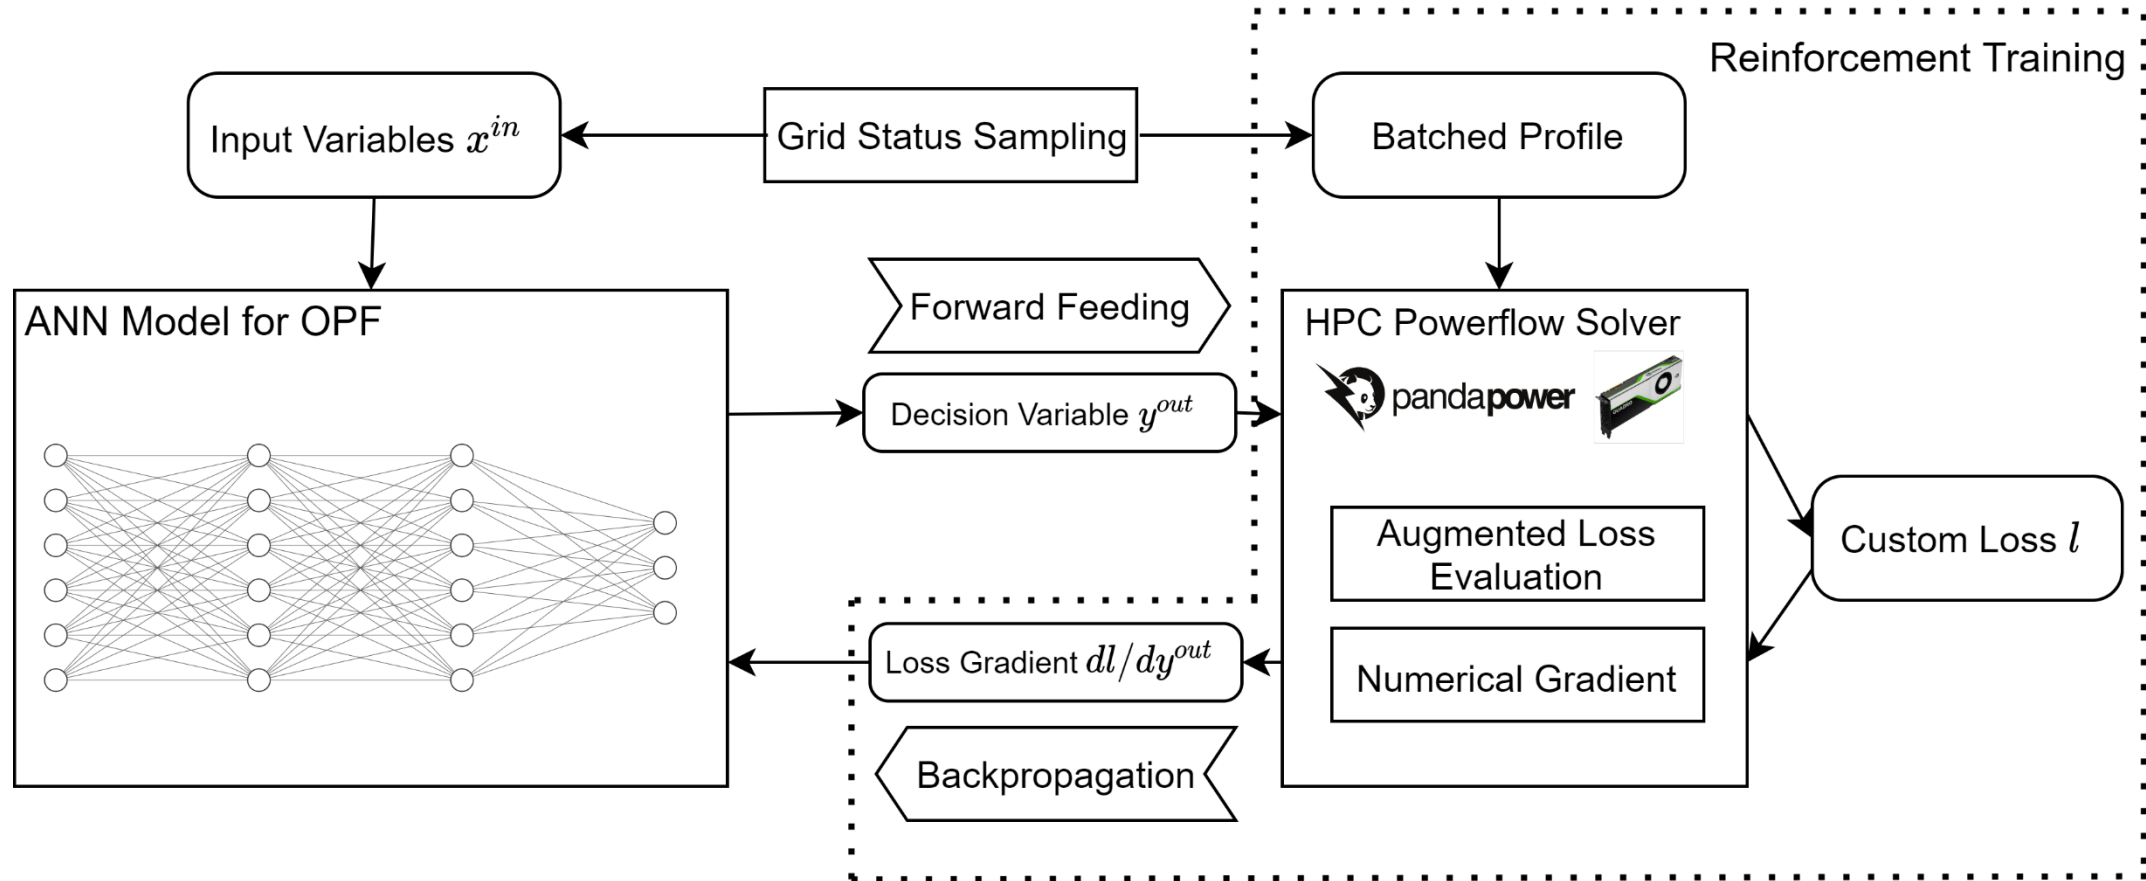


$$V_{\text{lower}} \leq V_b \leq V_{\text{upper}} \quad \forall b \in \{1, 2, \dots, n_{\text{buses}}\}$$

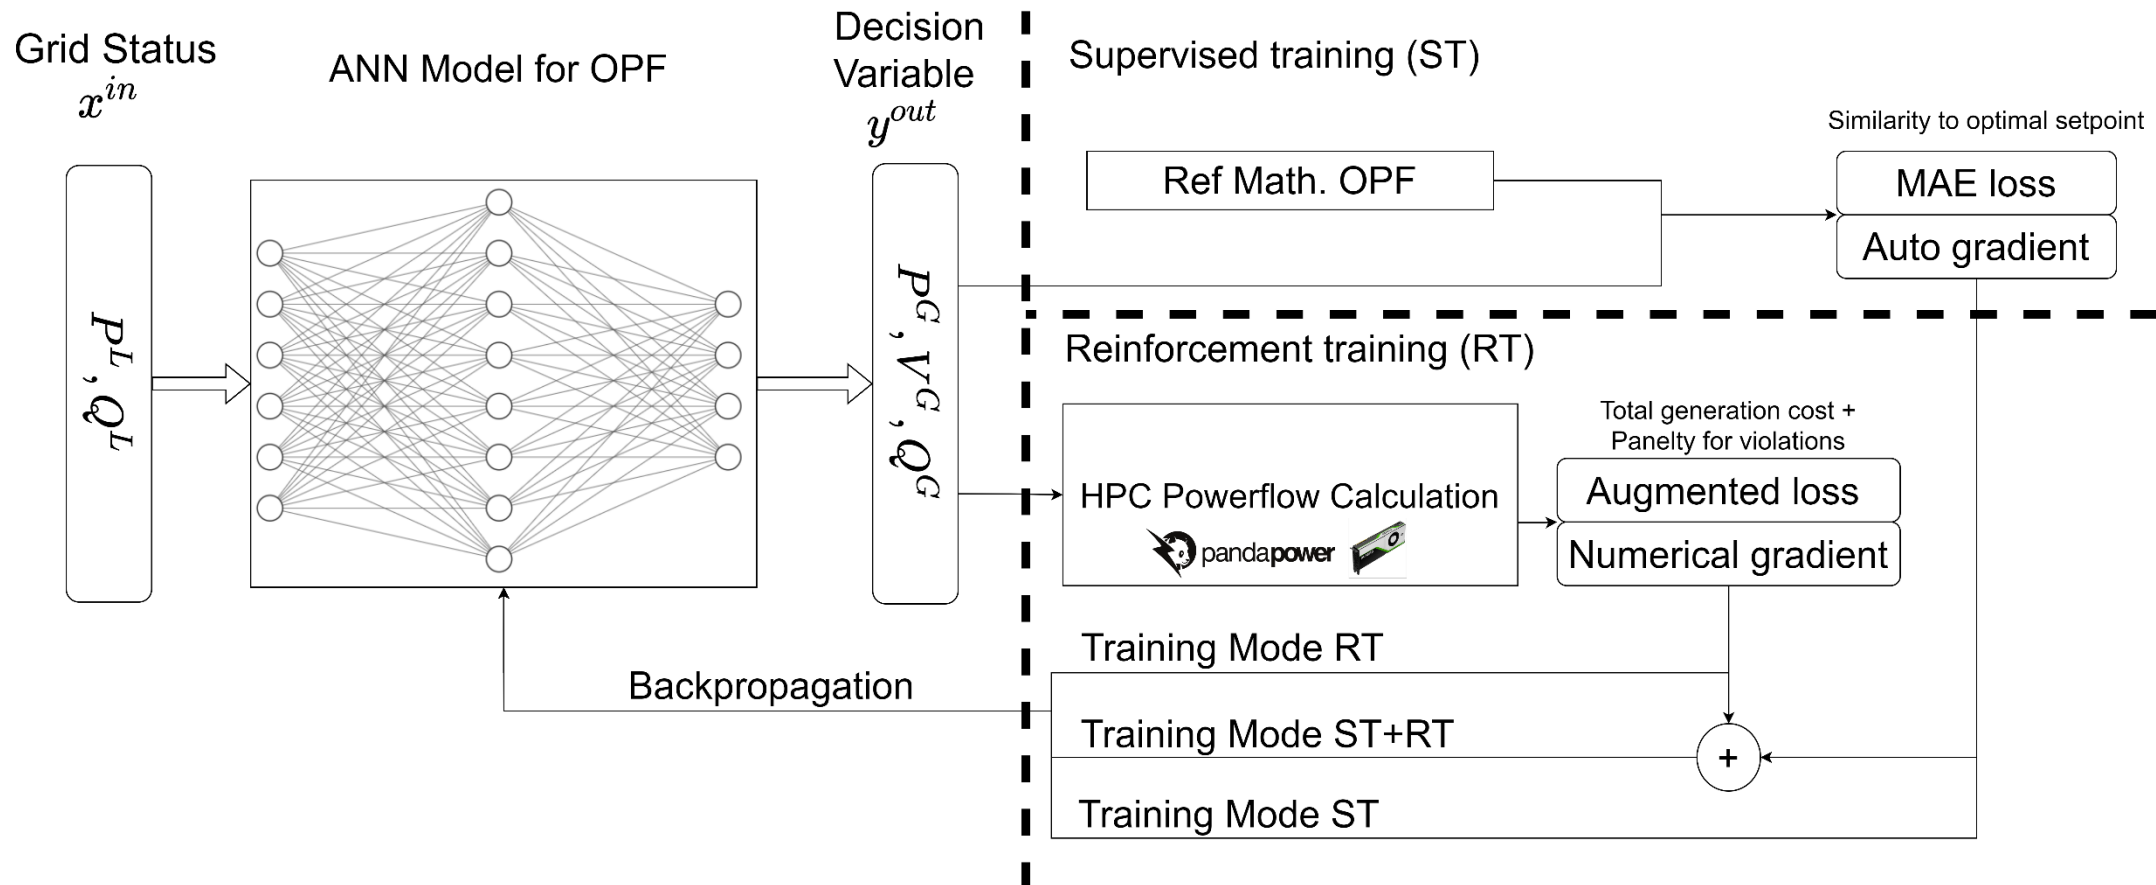
$$L_l \leq L_{\text{upper}} \quad \forall l \in \{1, 2, \dots, n_{\text{lines}}\}$$

$$L_t \leq L_{\text{upper}} \quad \forall t \in \{1, 2, \dots, n_{\text{transformers}}\}$$

# KI-OPF - Trainingsumgebung



# KI-OPF - Trainingsumgebung & Trainingsmodus



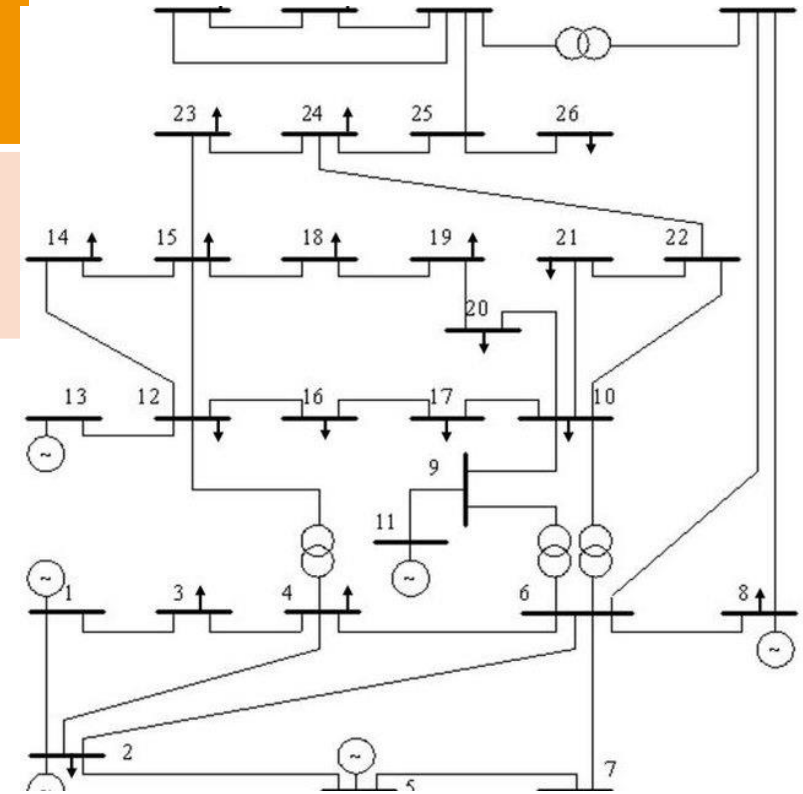


# Verlustminimierung mit IEEE case30

	Ref Math. OPF	KI OPF (RT)	KI OPF (ST)	KI OPF (ST + RT)
Netzverluste (MW)	1,589	2,15 (35,2%)	1,57 (~)	<b>1,61 (1,3%)</b>

## ■ Rechenperformance

- Math. OPF: 654 ms
- KI OPF: 0,9 ms (~ x700 schneller)
- KI OPF (ST+RT) kann auch unbekannte effektiv Zustände lösen



# Kognitive Energiesysteme: KI-Spotlight Probabilistische Netzzustandsprognosen

Dr. Sebastian Wende-von Berg,

Mike Vogt, Arne Wessel, Marcel Dipp, Malte Sievert

## Motivation | Ziele

- Prognosen sind für den Netzbetrieb bereits notwendig
- Erwartungswertprognosen sind KEINE Fahrpläne  
→ Unsicherheiten und gemittelte Netzzustände
- Probabilistische Netzzustandsprognosen berücksichtigen auch unwahrscheinlichere Netzzustände und bilden somit die Wirklichkeit genauer ab
- Umsetzung im Rahmen der Spotlight Projekte des K-ES



# Probabilistische Wind-/ PV-Prognosen mittels Wetterensembles



- 20 variierende Wetterprognosen (Ensemblemember) aus dem Modell Cosmo-D2 des DWD spiegeln die Unsicherheit der Prognose wieder.
- Daraus wurden erstellt:
  - 20 x Leistungsprognosen Wind (generalisierte Leistungskennlinie)
  - 20 x Leistungsprognosen PV (SPS Modell + Nachprozessierung)

Für die nächsten 48 Stunden für jeden Wind/PV Park aggregiert auf die Umspannwerke

- Ist die Prognose **unsicher** sind die Ensemblemember **unterschiedlicher**, ist sie **sicher** zeigen sie ein **gleichförmiges** Verhalten.


Cosmo-DE  
Ensemblemodell

Variationen im  
Vorhersagesystem



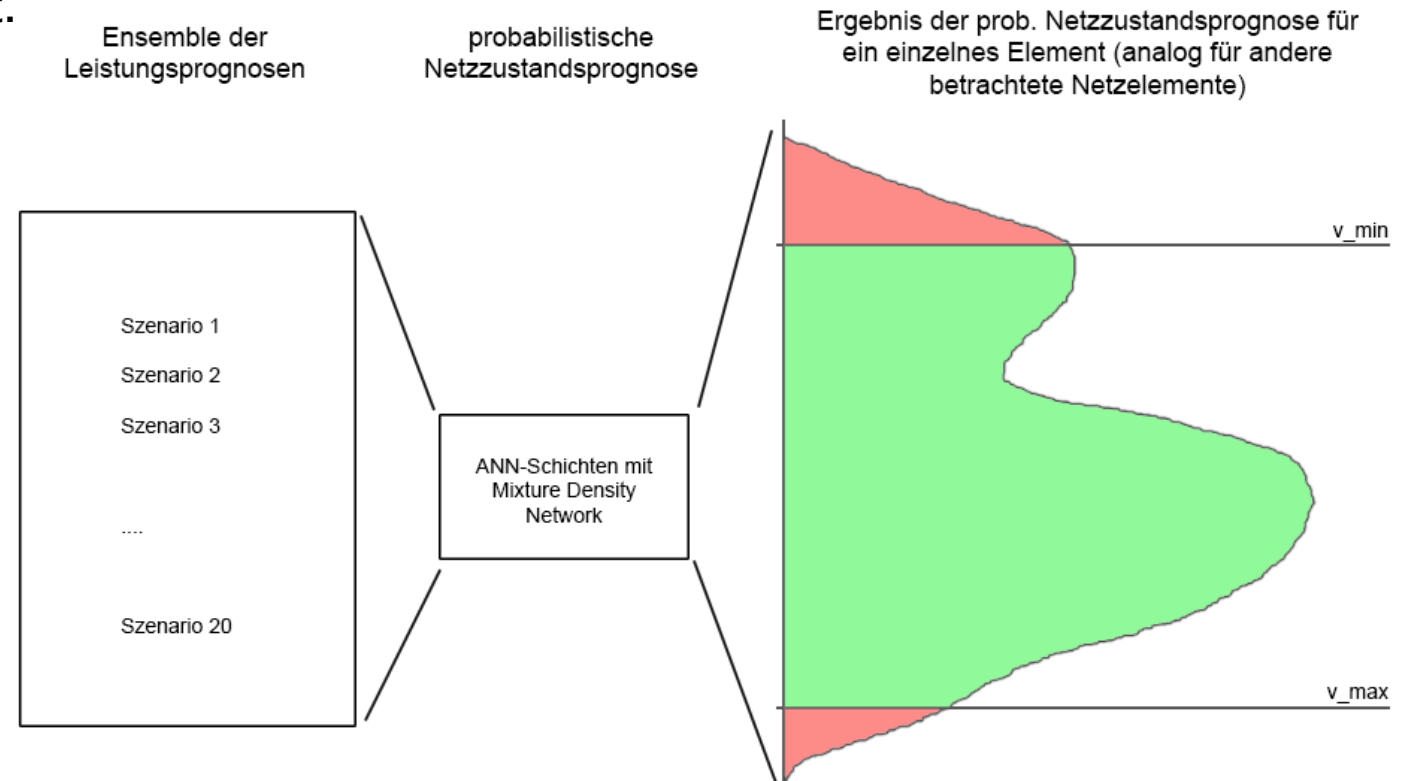
Aus „Beschreibung des operationellen Kurzzeitvorhersagemodells COSMO-D2 und COSMO-D2-EP5 und seiner Ausgabe in die Datenbanken des DWD“; DWD 2018

SPS  
PV-Modell



# Szenariobasierte Netzzustandsprognose

- Szenarioprognosen bilden für z.B. ein Netzgebiet mehrere Realisierungen pot. Einspeisung mit unterschiedlichen Wahrscheinlichkeiten ab.
- Jedes dieser Szenarien führt zu einem Netzzustand, der nun eine gewisse Wahrscheinlichkeit besitzt.
- Verschiedene Möglichkeiten, diese Netzszenarien zu aggregieren
  - Erwartungswert
  - Nach Ähnlichkeiten
  - Nach Engpasswahrscheinlichkeit
  - ...



<https://www.youtube.com/watch?v=CGiGA1Wa7EQ>

## PROBABILISTISCHE NETZZUSTANDSPROGNOSEN


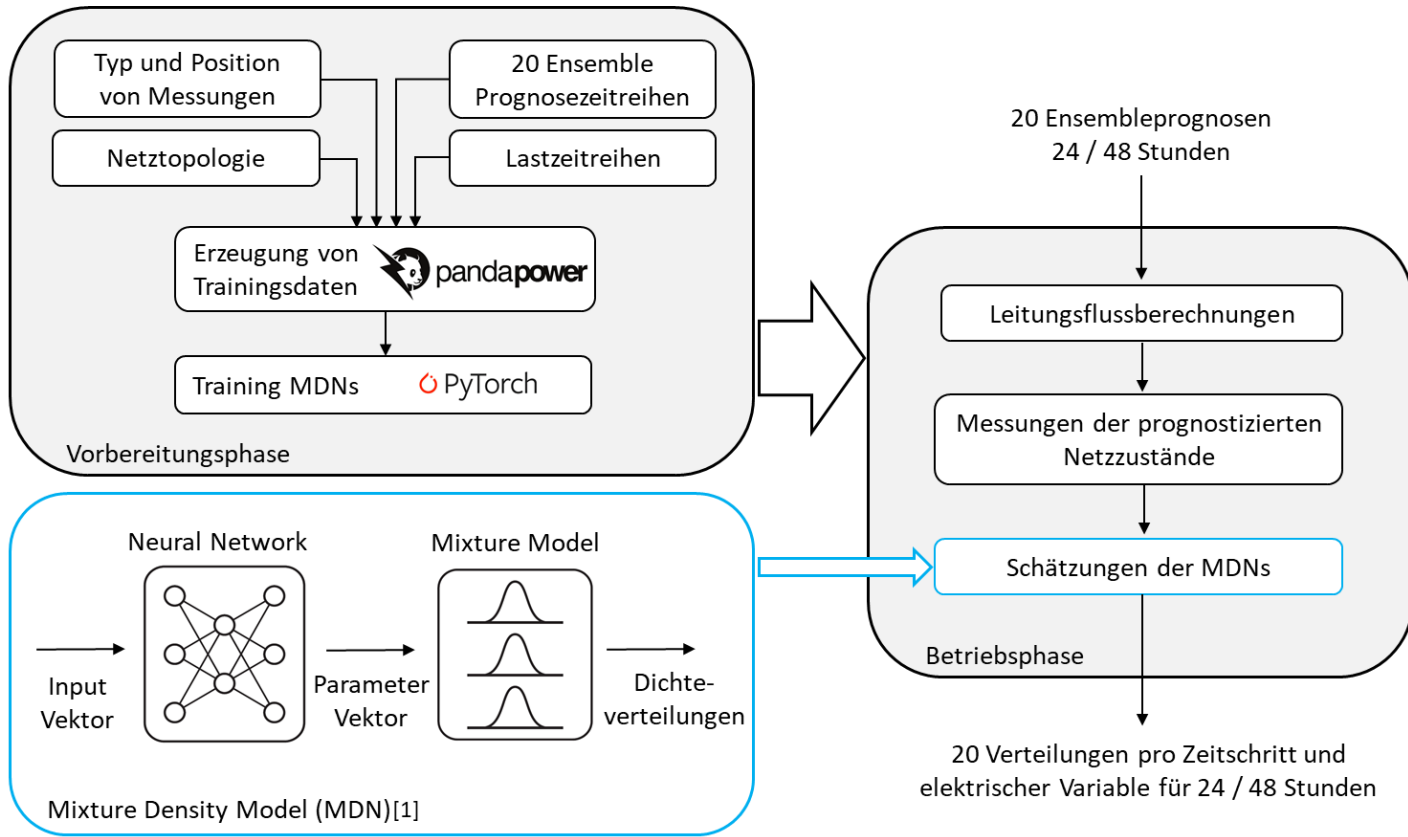
01:56

50





# Methodik der probabilistischen Netzzustandsprognose mittels MDN



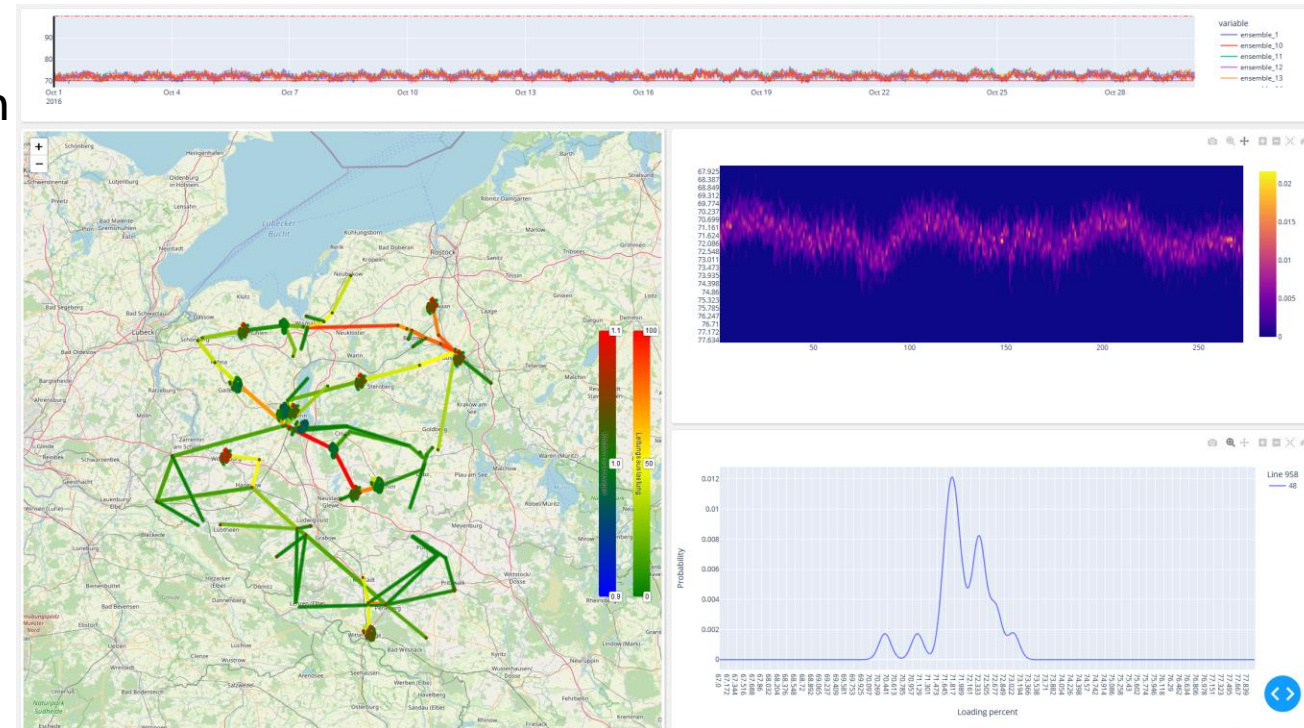
# Kognitive Energiesysteme: KI-Spotlight Probabilistische Netzzustandsprognosen

## Anwendung

- Erkennen von alternativen Netzsituationen
- Bessere Einschätzung und Dimensionierung von Redispatchmaßnahmen
- Prädiktive Maßnahmenbestimmung um Netzengpässe im Vorfeld auszuschließen

## Perspektiven

- Optimierungsansätze um nur „bestimmte“ Netzzustände zu realisieren
- Umsetzung der prototypischen Anwendung in eine operative Anwendung





# Zusammenfassung

- Anwendungen mithilfe Methoden aus KI und ML sind in der Energietechnik nicht mehr wegzudenken
- Die zunehmende Komplexität, und die steigende Vielfalt an Daten/Informationen erfordern immer neue Wege und Hilfsmittel das Energiesystem verlässlich und sicher zu gestalten
- KI lässt sich vor allem dort zielbringend anwenden, wo z.B.
  - klassische Methoden aufgrund von hohen Rechenaufwänden zu langsam sind
  - Korrelationen in den Daten nicht direkt abgebildet werden können
  - Daten fehlen und reproduziert werden müssen
  - Nicht-lineare Daten inter- oder extrapoliert werden müssen
- KI wird vermutlich auch in Zukunft nicht selbstständig handeln, sondern Entscheidungsprozesse (auch automatisierte) unterstützen

Vielen Dank für die Aufmerksamkeit und das Interesse