

Klassische Stromnetzberechnung in Kombination mit künstlicher Intelligenz zur Analyse und Diagnose von Stromverteilnetzen

Andreas Winter, Prof. Dr. Michael Igel
Hochschule für Technik und Wirtschaft des Saarlandes

Dr. Boris Brandherm
Deutsches Forschungszentrum für
Künstliche Intelligenz GmbH

Prof. Dr. Peter Schegner
Technische Universität Dresden



Gefördert durch:



aufgrund eines Beschlusses
des Deutschen Bundestages




Andreas Winter, Boris Brandherm, Michael Igel, Peter Schegner

Klassische Stromnetzberechnung in Kombination mit künstlicher Intelligenz zur Analyse und Diagnose von Stromverteilnetzen

Tutorial Schutz- und Leittechnik: Online Preview 2022


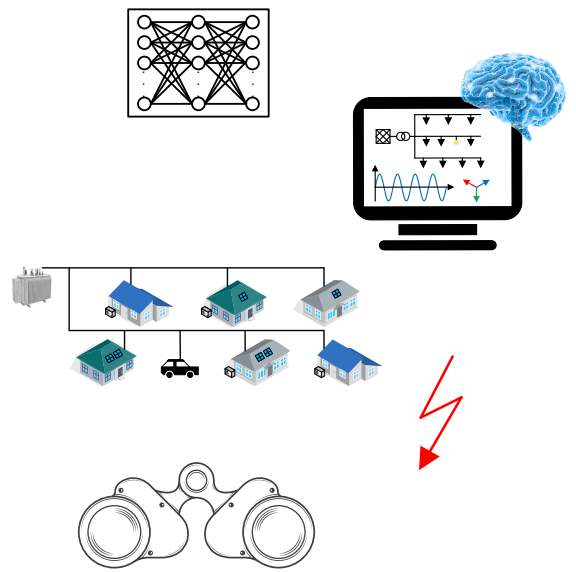


htw saar




Inhalt

- ➔ Grundlagen Künstliche Neuronale Netze (KNN)
- ➔ KI-basierte Netzsimulation
- ➔ Anwendung der KI-basierten Netzsimulation
- ➔ KI in der Netzschutztechnik
- ➔ Zusammenfassung und Ausblick



ARTIFICIAL INTELLIGENCE

Early artificial intelligence stirs excitement.



MACHINE LEARNING

Machine learning begins to flourish.



DEEP LEARNING

Deep learning breakthroughs drive AI boom.



1950's

1960's

1970's

1980's


1990's

2000's


2010's

Der Ursprung der KI reicht bis in die 1950er-Jahre zurück. Seit einem **frühen Anflug von Optimismus** hat die KI **Höhen und Tiefen durchlebt**. In den letzten Jahren haben nun kleinere Teilbereiche der Künstlichen Intelligenz –zunächst das maschinelle Lernen, dann Deep Learning– **immer größere Umwälzungen** bewirkt.


Biologisches Vorbild – Nervenzelle



Biologisches Vorbild – Nervenzelle

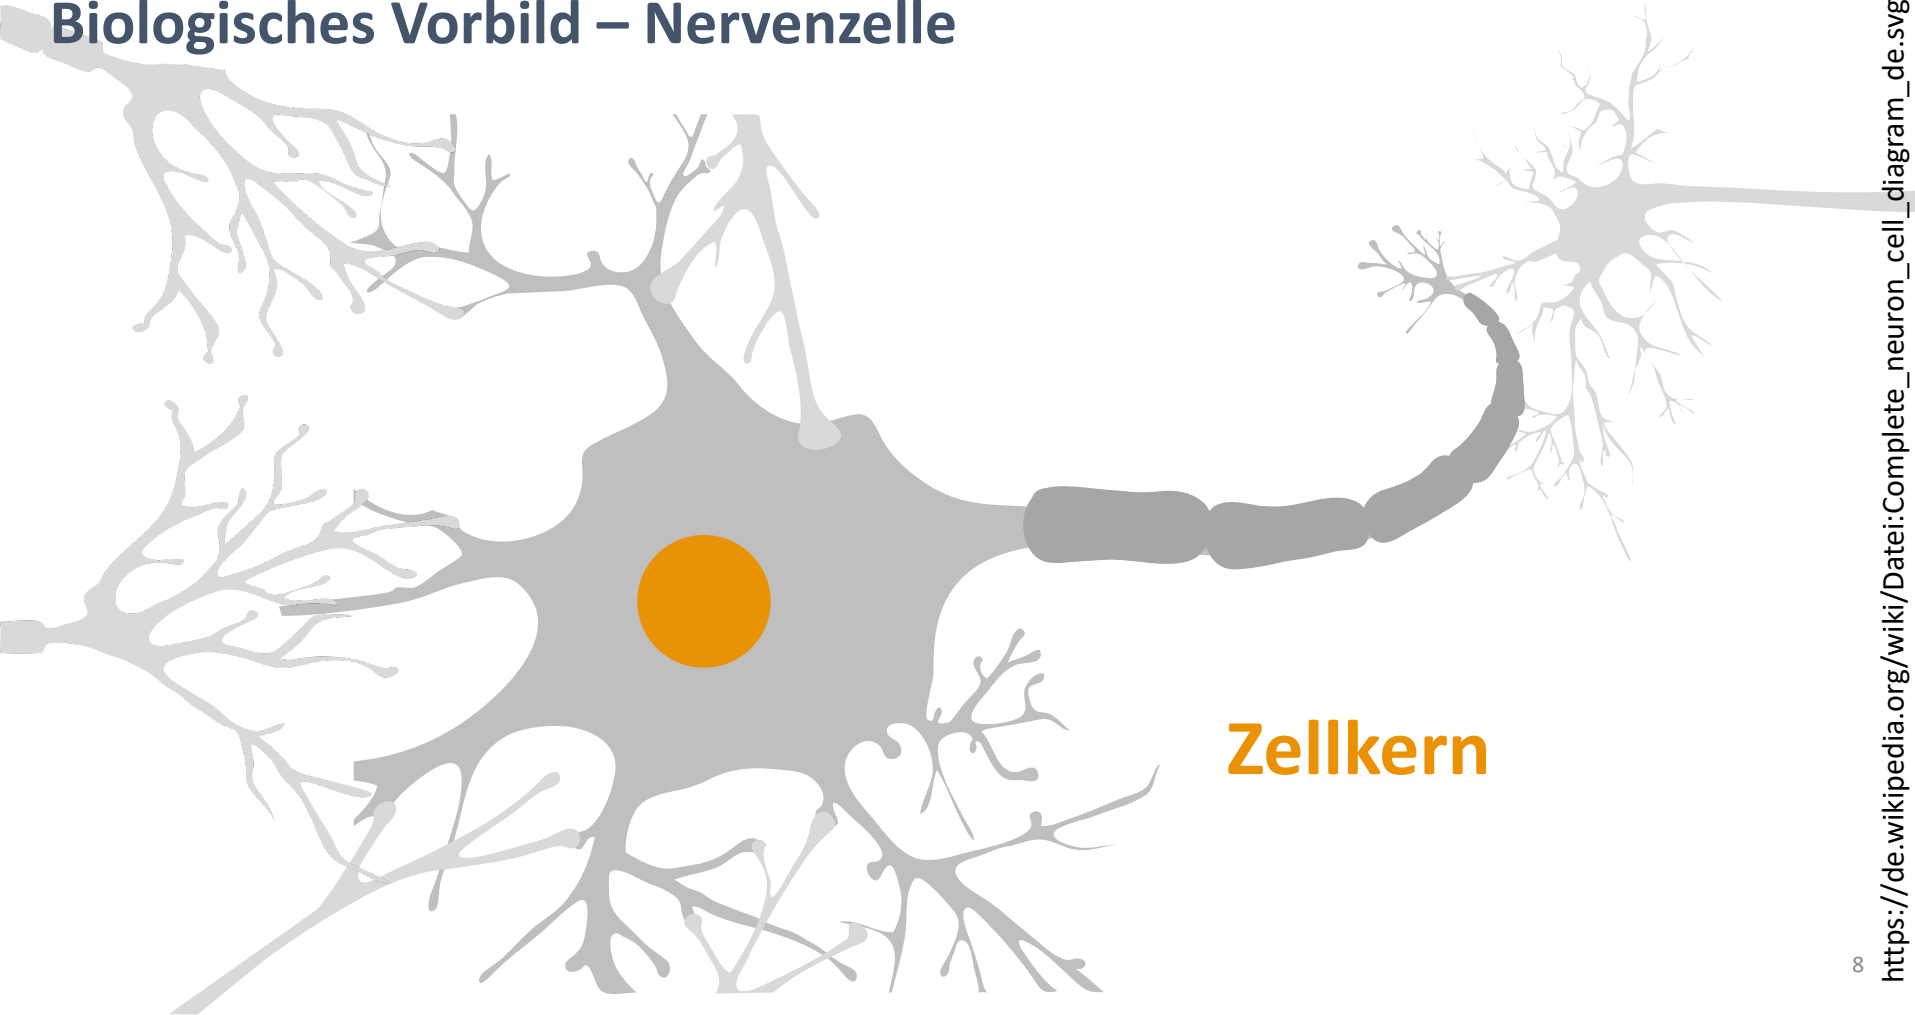


Biologisches Vorbild – Nervenzelle




Zellkörper = Soma

Biologisches Vorbild – Nervenzelle




Zellkern

Biologisches Vorbild – Nervenzelle




Dendriten


Biologisches Vorbild – Nervenzelle




Biologisches Vorbild – Nervenzelle




Biologisches Vorbild – Nervenzelle




Biologisches Vorbild – Nervenzelle



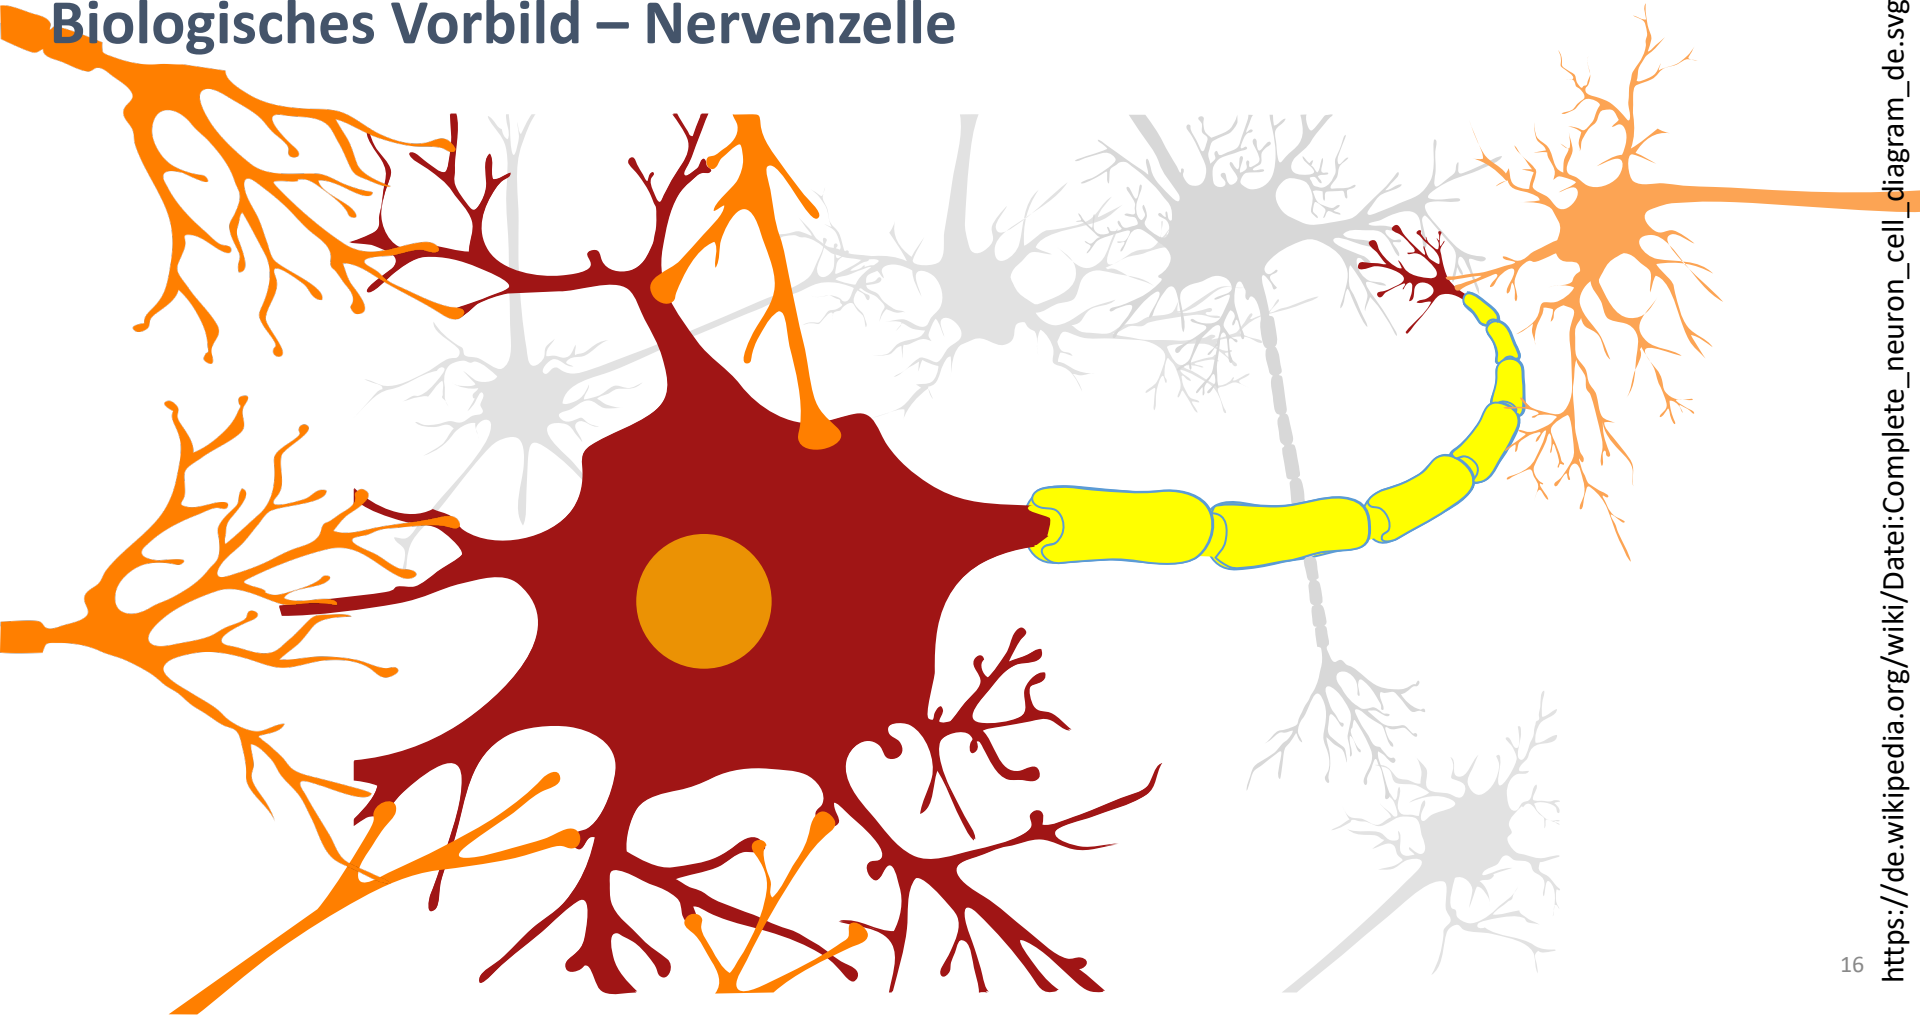
Biologisches Vorbild – Nervenzelle




Biologisches Vorbild – Nervenzelle




Biologisches Vorbild – Nervenzelle




Biologisches Vorbild – Nervenzelle




Biologisches Vorbild – Nervenzelle (Neuron)




Biologisches Vorbild – Nervenzelle (Neuron)




Biologisches Vorbild – Nervenzelle (Neuron)




Biologisches Vorbild – Nervenzelle (Neuron)




Biologisches Vorbild – Nervenzelle (Neuron)




Biologisches Vorbild – Nervenzelle (Neuron)



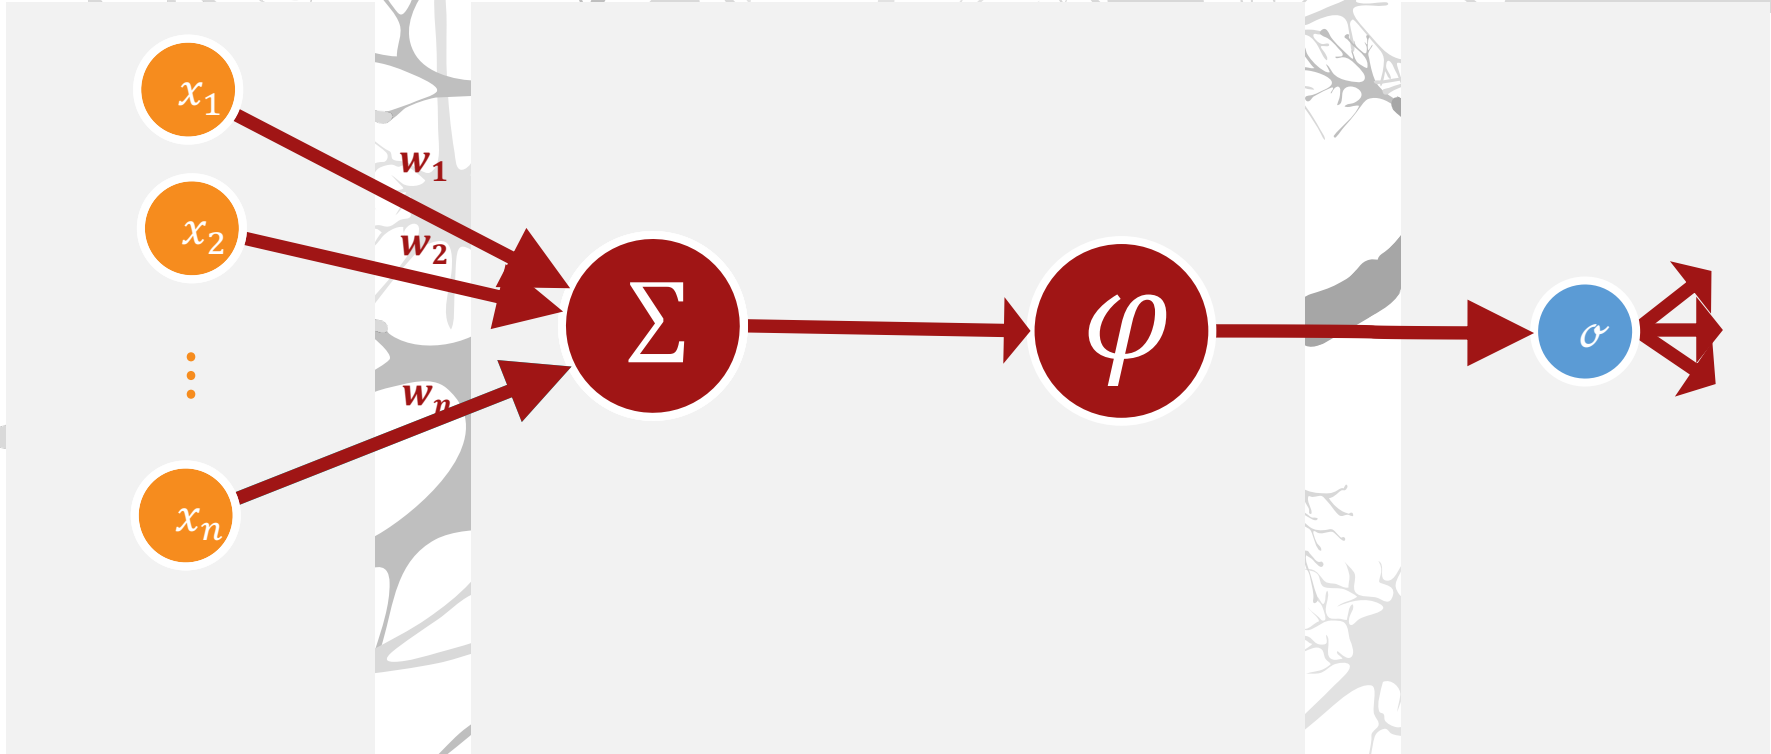
Biologisches Vorbild – Nervenzelle (Neuron)




Biologisches Vorbild – Nervenzelle (Neuron)



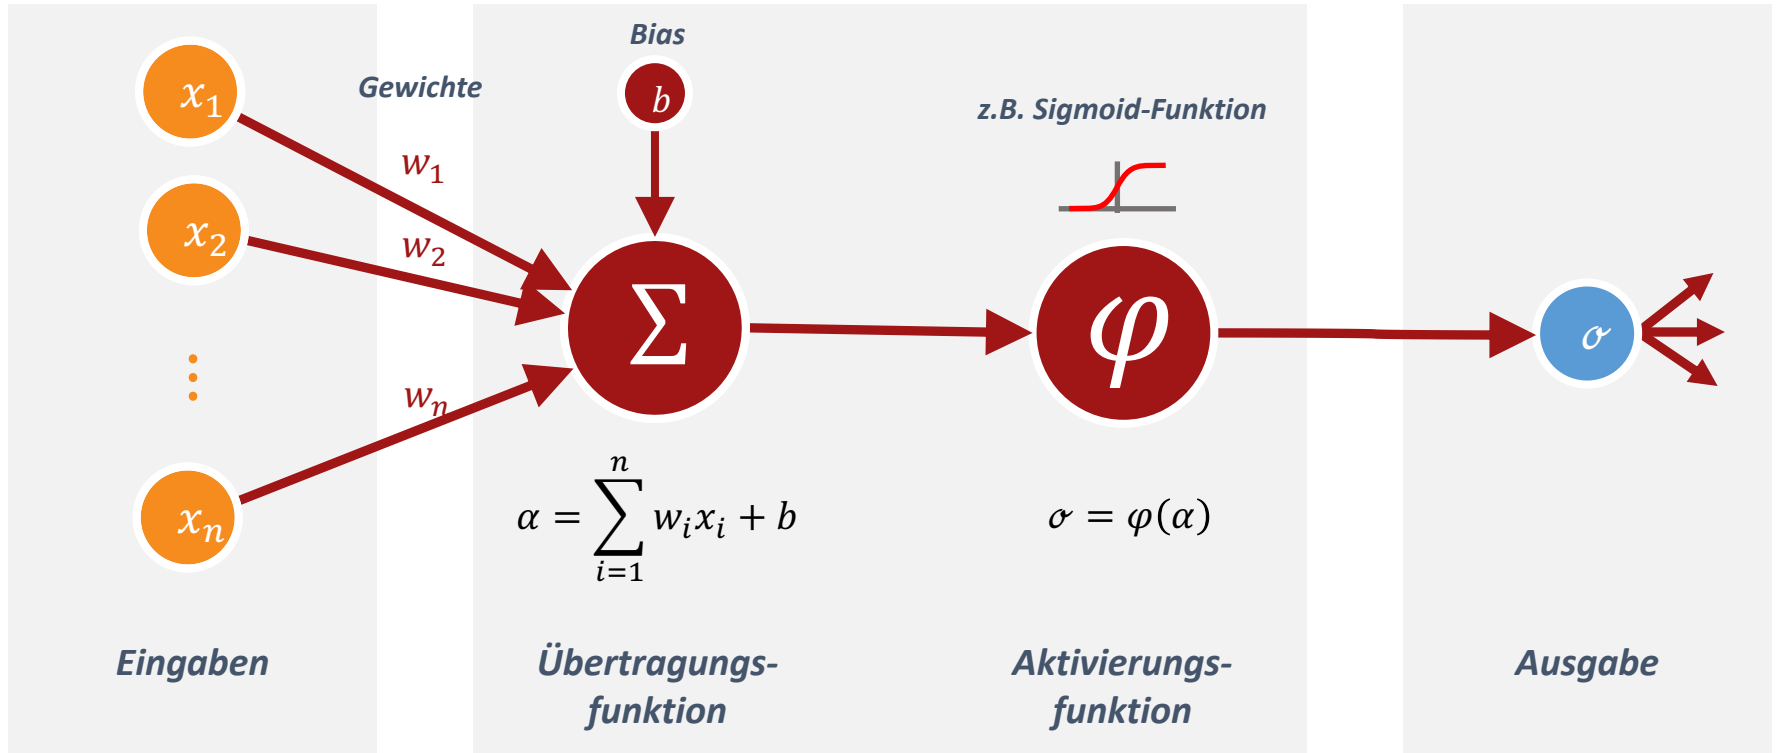
Künstliches Neuron und seine Funktionsweise



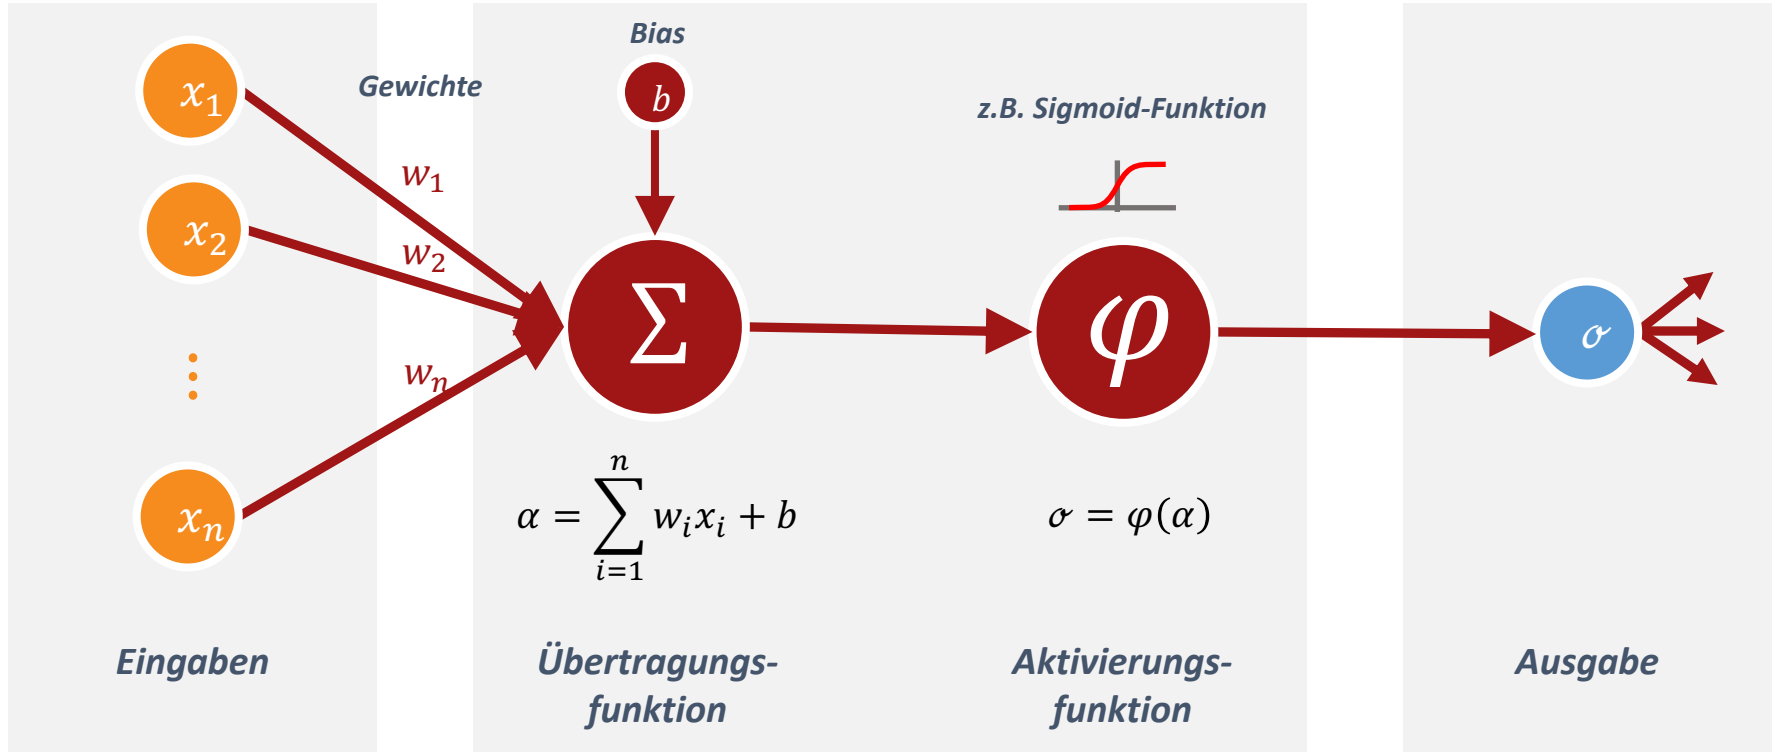
Künstliches Neuron und seine Funktionsweise



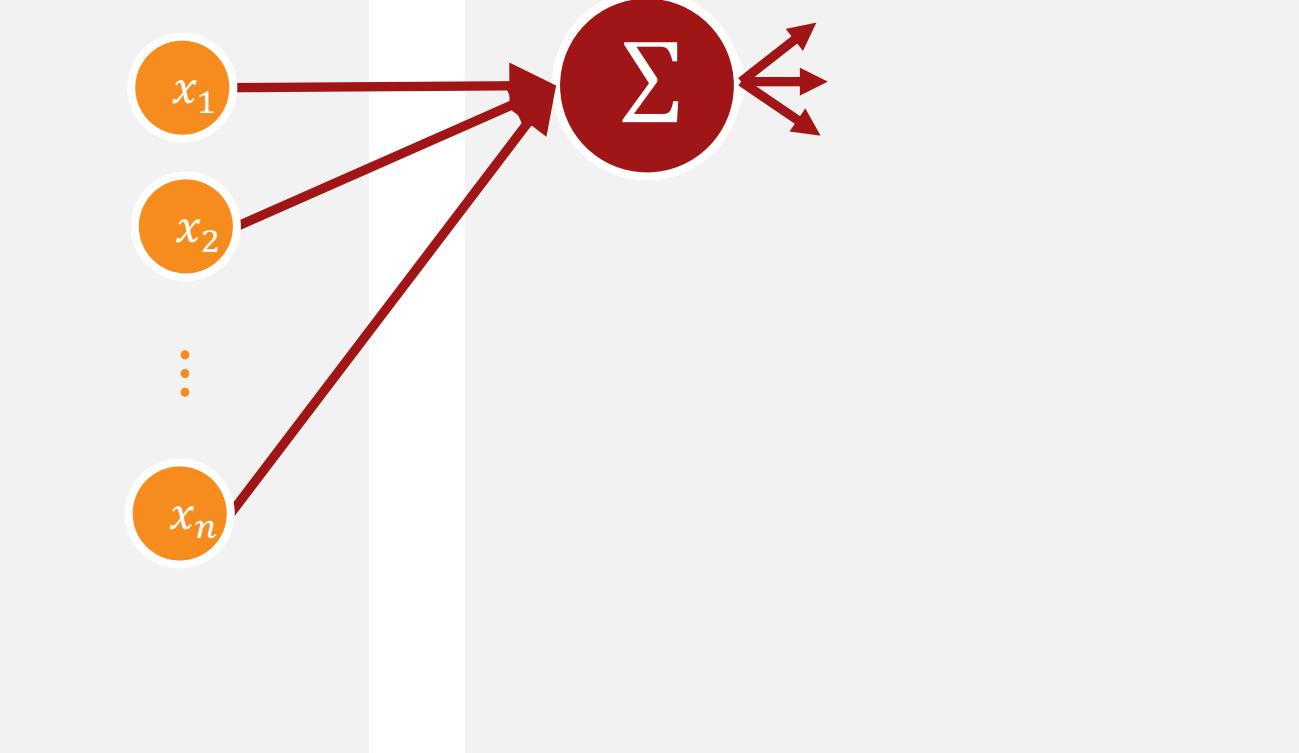
Künstliches Neuron und seine Funktionsweise



Künstliches Neuron – Teil eines Neuronalen Netzes




Künstliches Neuron – Teil eines Neuronalen Netzes



Künstliches Neuron – Teil eines Neuronalen Netzes




Künstliches Neuron – Teil eines Neuronalen Netzes



Eingabeschicht
 U_0

Verborgene Schicht
 U_1


...




Verborgene Schicht
 U_{H-2}

Ausgabeschicht
 U_{H-1}



Künstliches Neuron – Teil eines Neuronalen Netzes




...




Künstliches Neuron – Teil eines Neuronalen Netzes



Neuronales Netz – Berechnung




...




Jetzt können wir auch ein komplexeres Beispiel mit mehreren Neuronen und Schichten rechnen.

Neuronales Netz – Berechnung




Das Netz erhält einen Eingabevektor $\vec{x} = (x_1, \dots, x_n)$ als Eingabe.

Neuronales Netz – Berechnung




Das Netz erhält einen Eingabevektor $\vec{x} = (x_1, \dots, x_n)$ als Eingabe.

Neuronales Netz – Berechnung



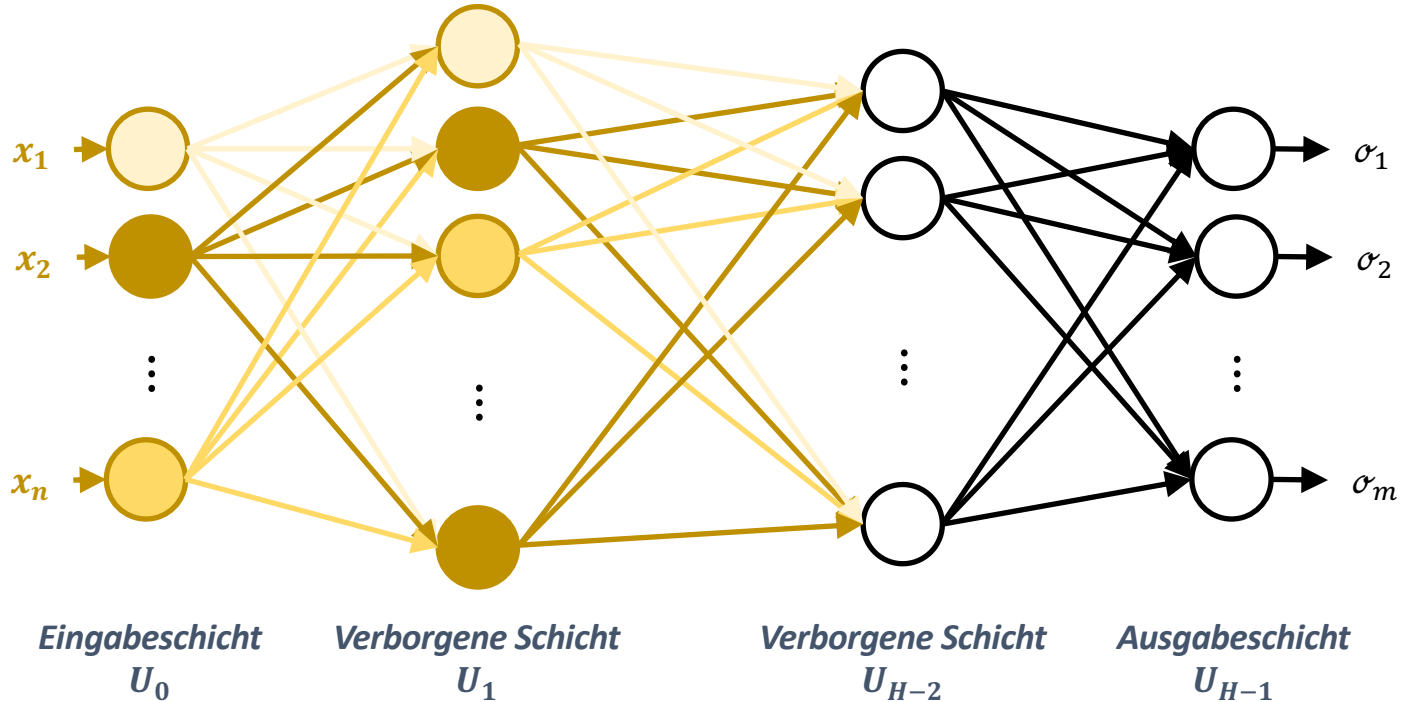
Das Netz erhält einen Eingabevektor $\vec{x} = (x_1, \dots, x_n)$ als Eingabe.

Neuronales Netz – Berechnung




Das Netz erhält einen **Eingabevektor** $\vec{x} = (x_1, \dots, x_n)$ als Eingabe.

Neuronales Netz – Berechnung



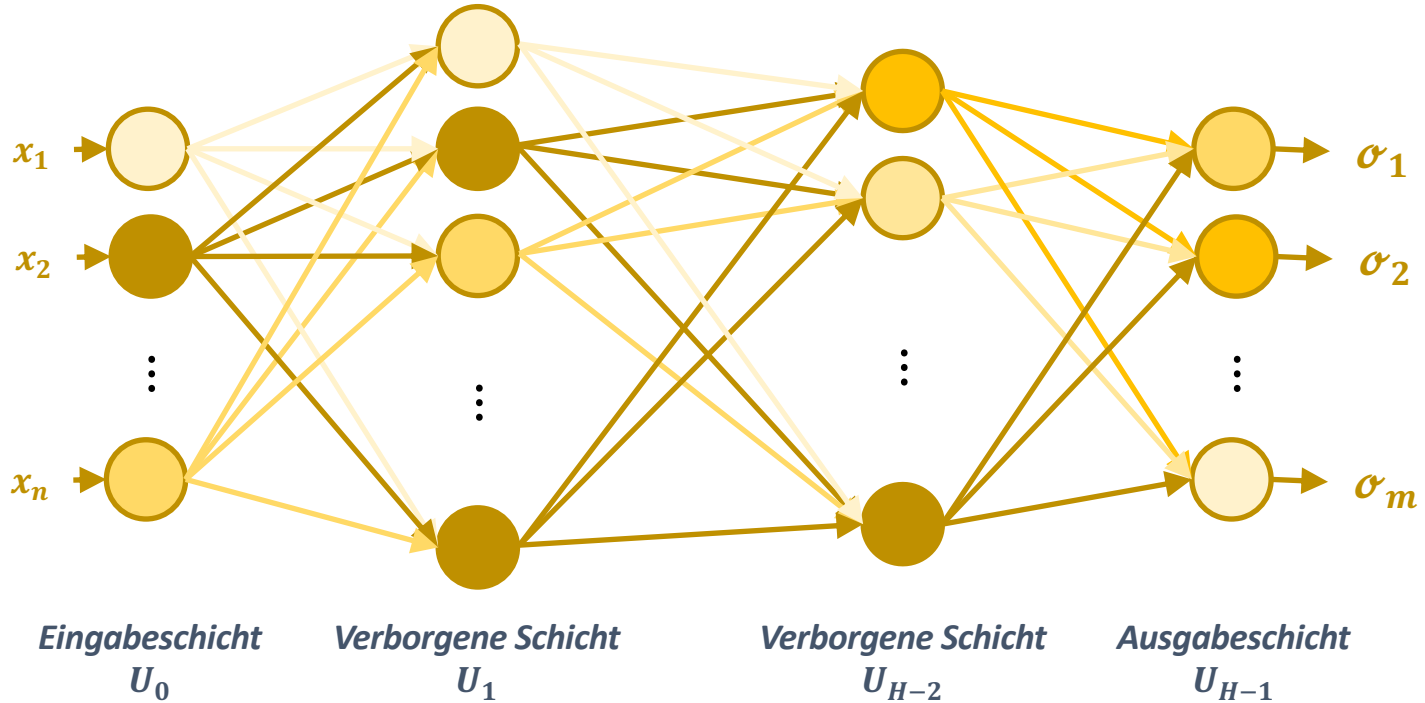
In der Schicht U_1 wird bei jedem Neuron zunächst über die **Übertragungsfunktion** die Aktivierung und dann über die **Aktivierungsfunktion** die Ausgabe ermittelt.

Neuronales Netz – Berechnung



Die Daten durchlaufen somit das Netz Schicht für Schicht (von links nach rechts).

Neuronales Netz – Berechnung



Die Ausgabeschicht U_{H-1} liefert am Ende eine Ausgabe

$$\vec{\sigma}_{H-1} = (\sigma_{H-1,1}, \dots, \sigma_{H-1,m}) = \vec{\sigma} = (\sigma_1, \dots, \sigma_m).$$

Lernen eines Neuronales Netzes

Wir haben gesehen, dass sich ein Neuronales Netz sehr einfach berechnen lässt. Wie wir im Folgenden sehen werden, ist es jedoch sehr aufwändig, ein Neuronales Netz zu lernen. Warum ist das so?

Man kann das Lernen eines Neuronales Netzes in etwa mit der Primfaktorzerlegung vergleichen. Die Multiplikation zweier Zahlen ist sehr einfach. Das Zerlegen einer Zahl in seine Primzahlen (insbesondere zweier sehr großer Primzahlen) ist jedoch sehr aufwändig und schwierig. Darauf beruht u.a. die Sicherheit des RSA-Kryptosystems. Wenn jemand die Primfaktorzerlegung schnell berechnen kann, dann kann er auch die mit RSA verschlüsselten Texte entschlüsseln.

Wenn man beim Lernen eines Neuronales Netzes bei der Analogie der Primfaktorzerlegung bleibt, dann kommt hinzu, dass man noch nicht einmal die Zahl kennt, die in ihre Primfaktoren zerlegt werden soll. (Dies ist bei der Primfaktorzerlegung allerdings nicht der Fall; da kennt man die zu zerlegende Zahl.) Schauen wir uns diese „Blindheit“ im Folgenden genauer an.

$$\begin{aligned} 450 &= 2 * 225 \\ 450 &= 2 * 3 * 75 \\ 450 &= 2 * 3 * 3 * 25 \\ 450 &= 2 * 3 * 3 * 5 * 5 \end{aligned}$$

Gradientenverfahren
Ziel: Finde das globale Minimum

Beispiel: Bergwandern

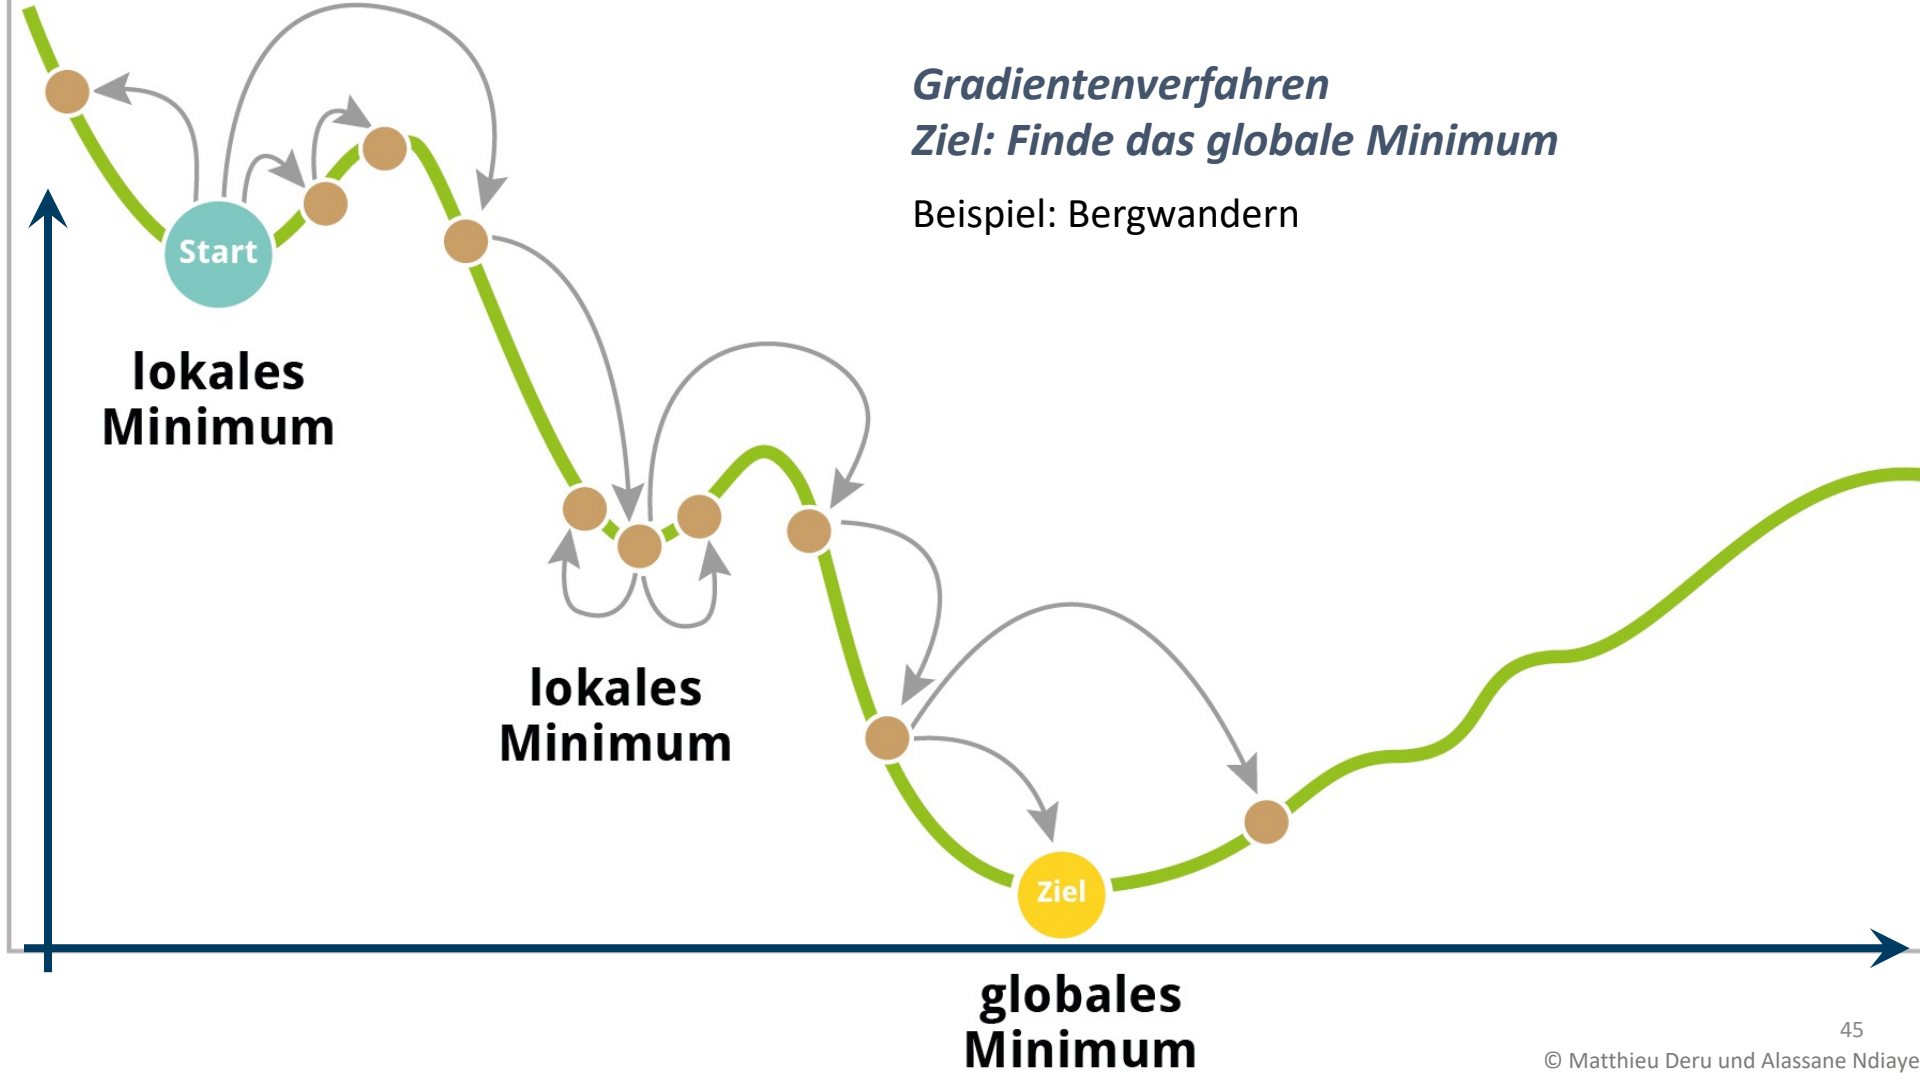


**lokales
Minimum**

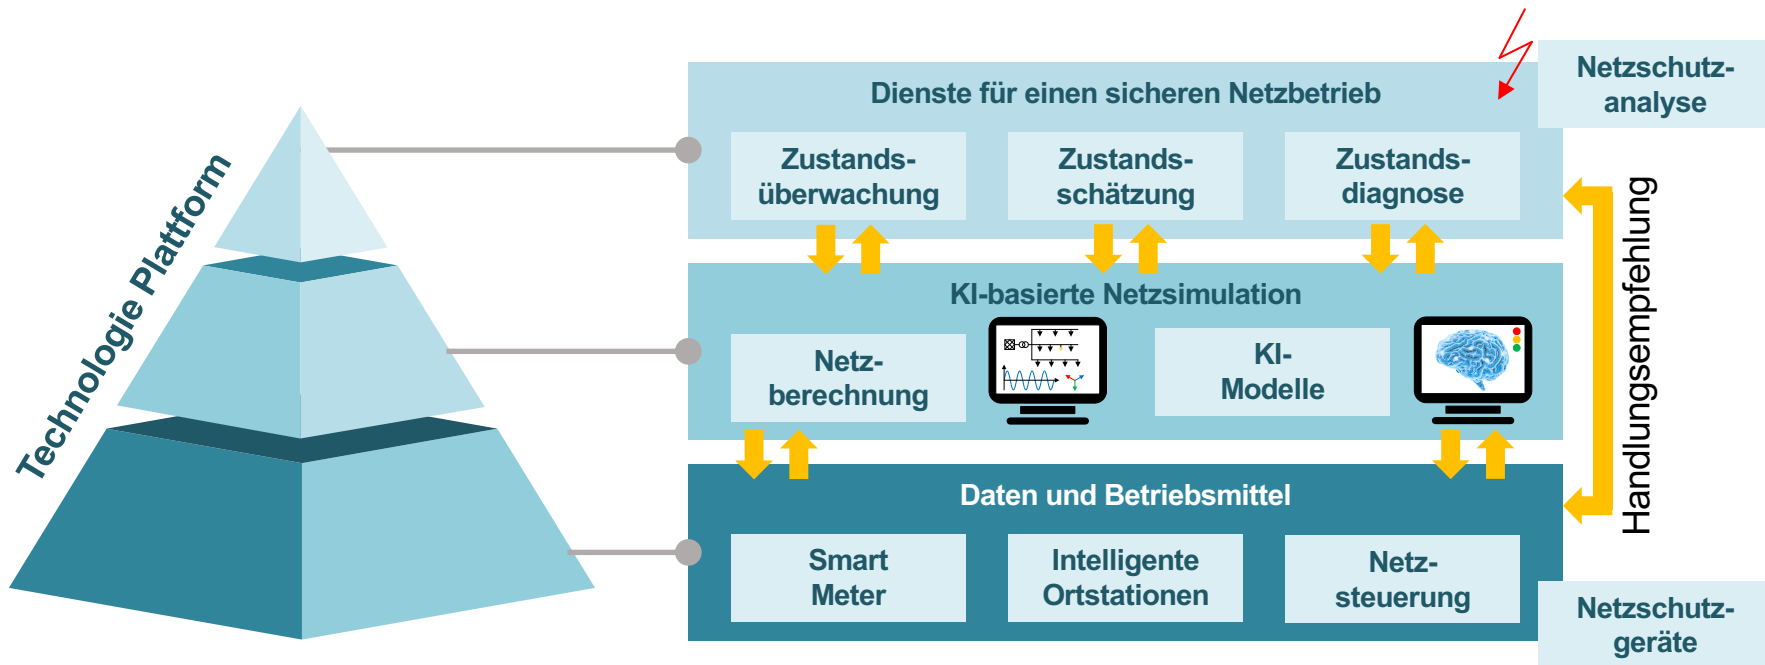
**globales
Minimum**

Gradientenverfahren
Ziel: Finde das globale Minimum

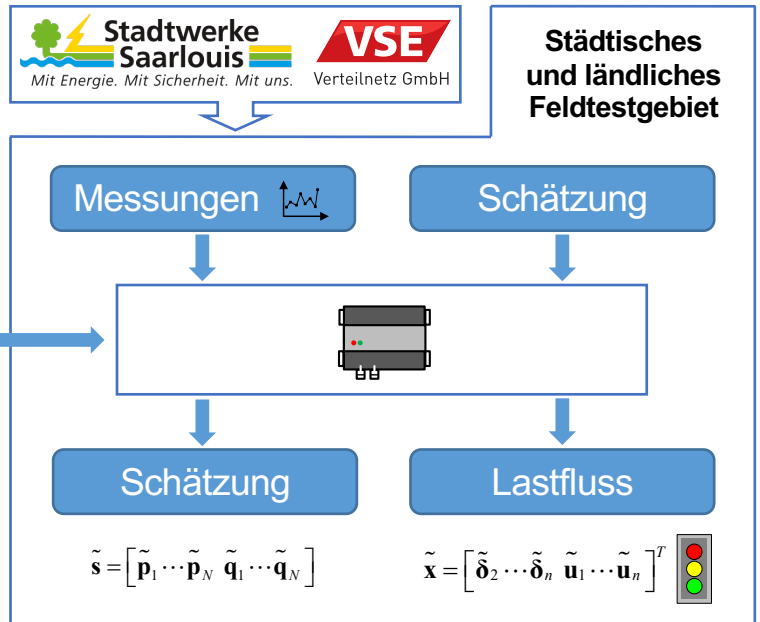
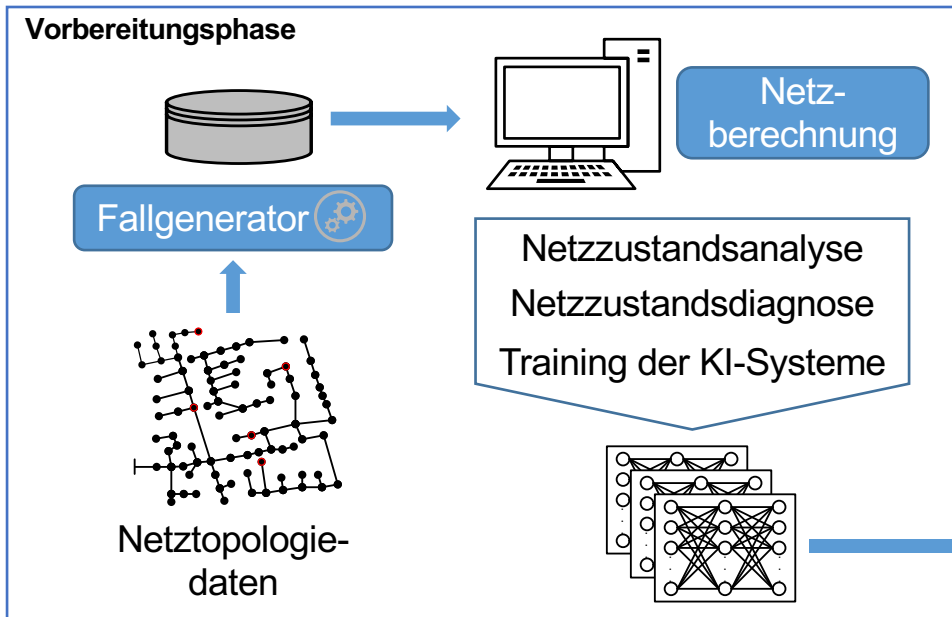
Beispiel: Bergwandern



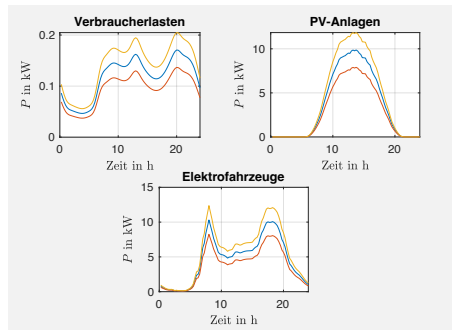

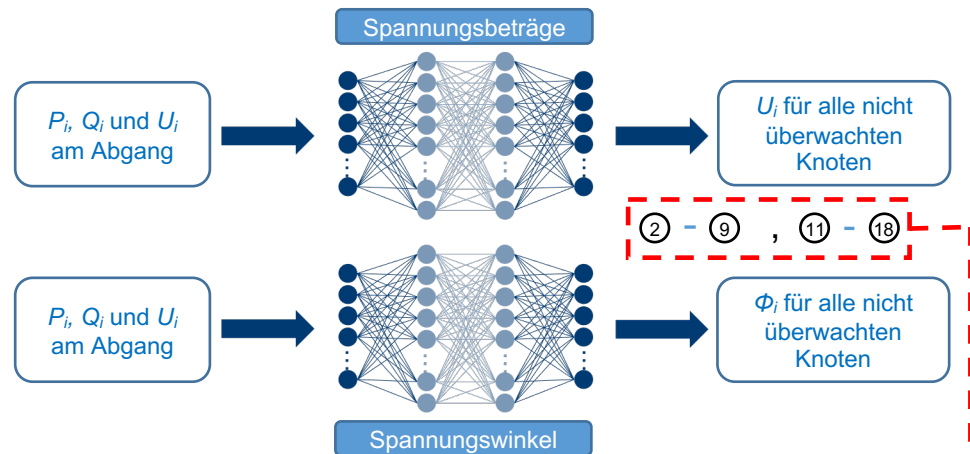
KI-basierte Netzsimulation



KI-basierte Netzsimulation



Vorbereitungsphase – KNN Modell




```

#####
# Neuronale Netz anlegen
#####
class MeinNetz(nn.Module):
    def __init__(self):
        nhidden = 20
        super(MeinNetz, self).__init__()
        self.lin1 = nn.Linear(3, nhidden)
        self.lin2 = nn.Linear(nhidden, nhidden)
        self.lin3 = nn.Linear(nhidden, nhidden)
        self.lin4 = nn.Linear(nhidden, nhidden)
        self.lin5 = nn.Linear(nhidden, 18)

    def forward(self, x):
        x = F.relu(self.lin1(x))
        x = F.relu(self.lin2(x))
        x = F.relu(self.lin3(x))
        x = F.relu(self.lin4(x))
        x = self.lin5(x)
        return x
    
```

233.937 Szenarien




Fallgenerator

GPU-Server




Training der KNN


Validierung der KNN – Relative Fehler




MC1



MC2



MC3



$$e_U = \frac{U_{L1E,KI} - U_{L1E,wahr}}{\frac{U_n}{\sqrt{3}}}$$



$$-1 \% \leq e_U \leq 1 \%$$

$$e_I = \frac{I_{L1,KI} - I_{L1,wahr}}{I_r}$$

$$-10 \% \leq e_I \leq 10 \%$$

Anwendungsfall

➔ 96 mal 15-Minuten Intervalle  E-Mobile deaktiviert



E-Mobile unterer Abgang:



- Ladevorgang von **18:00 Uhr** bis **21 Uhr**
- **P = 22 kW** mit $\cos(\varphi) = 1$

Szenario 1 (Sz1)	Szenario 2 (Sz2)
S1 offen	S1 geschlossen
S2 offen	S2 geschlossen



Berücksichtigung unterschiedlicher Schaltzustände

Anwendungsfall im Stromnetz - Ergebnisse

Betrag Leiter-Erd-Spannung (Knoten 18)




Betrag Leiterstrom (Leitung 16)



▲ AI-SE-MC1
 × AI-SE-MC2
 ● AI-SE-MC3
 ■ True

➔ $|e_U| < 0,56 \%$ ✓
-1 % ≤ e_U ≤ 1 %

➔ $|e_I| < 3,2 \%$ ✓
-10 % ≤ e_I ≤ 10 %



AI-SE-MC1

- Überwachung der E-Mobile, PV-Anlagen und Ortsnetzstation

AI-SE-MC2


- Überwachung der PV-Anlagen und Ortsnetzstation

AI-SE-MC3

- Überwachung der Ortsnetzstation

Quelle: A. Winter 2021: 2

KI-Systeme für Kurzschlussstromberechnungen



- Verlagerung der rechenintensiven Trainingsphase in den Offline-Betrieb
- Berechnung einer großen Anzahl an KS-Szenarien mit geringen Rechenzeiten
- Anwendung für Typ- und Applikationsprüfungen für Netzschutzgeräte
- Anwendung für die Überprüfung von Netzschutzkonzepten

Zusammenfassung und Ausblick

- Offline: **Daten- und rechenintensive Trainingsphase → zeitunkritisch**
- **Onlinebetrieb:** Die KI-basierten Systeme liefern Ergebnisse **sehr schnell und robust gegenüber fehlenden Messdaten**
- **Onlinebetrieb: KI-Systeme schätzen den Netzzustand auch bei geringer Anzahl an Messsystemen**
- KI-basierte Berechnung der Lastflüsse: **geringer Rechenzeit unabhängig von der Anzahl der Netzknoten**

Ausblick

- Umsetzung der KI-basierten Netzsimulation in realen Stromnetzen
- Vergleich der Ergebnisse der KI-basierten Netzsimulation mit klassischen Verfahren
- Einsatz von KI-Systemen in der Netzschutztechnik
 - Prüfverfahren mit KI-basierter Stromnetzberechnung für Typprüfung und Anwendungsprüfung
 - Signifikante Reduktion der Prüfzeiten bzw. Erhöhung der Anzahl Prüfscenarien
 - Steigerung der Prüftiefe und Prüfqualität (Wegfall von Großkraftwerken und weiterem Zubau von DEAs)

Gefördert durch:



aufgrund eines Beschlusses
des Deutschen Bundestages



Vielen Dank für Ihre Aufmerksamkeit!



htw saar



Referenzen



- [1] Winter, A.; Igel, M.; Schegner, P. (2021): Supervised Learning Approach for State Estimation in Distribution Systems with missing Input Data. Hg. v. 2021 IEEE PES Innovative Smart Grid Technologies Europe (ISGT Europe). Espoo, Finland.
- [2] Winter, A.; Igel, M.; Schegner, P. (2020): Application of artificial intelligence in power grid state analysis and -diagnosis. In: Detlef Schulz (Hg.): NEIS 2020. Conference on Sustainable Energy Supply and Energy Storage Systems Hamburg, 14 - 15 September 2020. 1. Neuerscheinung. Berlin: VDE Verlag, S. 128–133.
- [3] Deru, M.; Ndiaye, A.: Deep Learning mit TensorFlow, Keras und TensorFlow.js. Rheinwerk Computing, 2. Auflage, 2020.
- [4] Brandherm, B.; Deru, M.; Ndiaye, A.; Kiefer, G.-L.; Baus, J.; Gampfer, R.: Integration erneuerbarer Energien – KI-basierte Vorhersageverfahren zur Stromerzeugung durch Photovoltaikanlagen. Angewandte Wirtschaftsinformatik. Springer Vieweg, 2021.
- [5] GridAnalysis – KI-basierte Systemanalyse von Stromverteilnetzen im Normal- und Kurzschlussbetrieb.
www.gridanalysis.de

Vielen Dank für Ihre Aufmerksamkeit

Ansprechpartner

Andreas Winter, M. Sc.

Institut für Elektrische Energiesysteme

Hochschule für Technik und Wirtschaft des Saarlandes

andreas.winter@htwsaar.de

Tel.: +49 681 5867-356