Bitte beachten Sie die Lizenzhinweise auf der letzten Seite

Foto: Jean-Philippe Delberghe on Unsplash

Aktivierungsfunktionen

in neuronalen Netzen

INNOVET
KI B³
Künstliche Intelligenz in die berufliche Bildung bringen

INNOVET
GEFÖRDERT VOM
Bundesministerium für Bildung und Forschung
bibb Bundesinstitut für Berufsbildung

Gefördert als InnoVET-Projekt aus Mitteln des Bundesministeriums für Bildung und Forschung.

Aktivierungsfunktion in Neuronalen Netzen

- Ziel: Nicht-Linearität
- Anfangs: meist Sigmoid-Funktion
- Heute: verschiedene andere nicht-lineare Funktionen
- Unterschied zwischen inneren Schichten und letzter Schicht

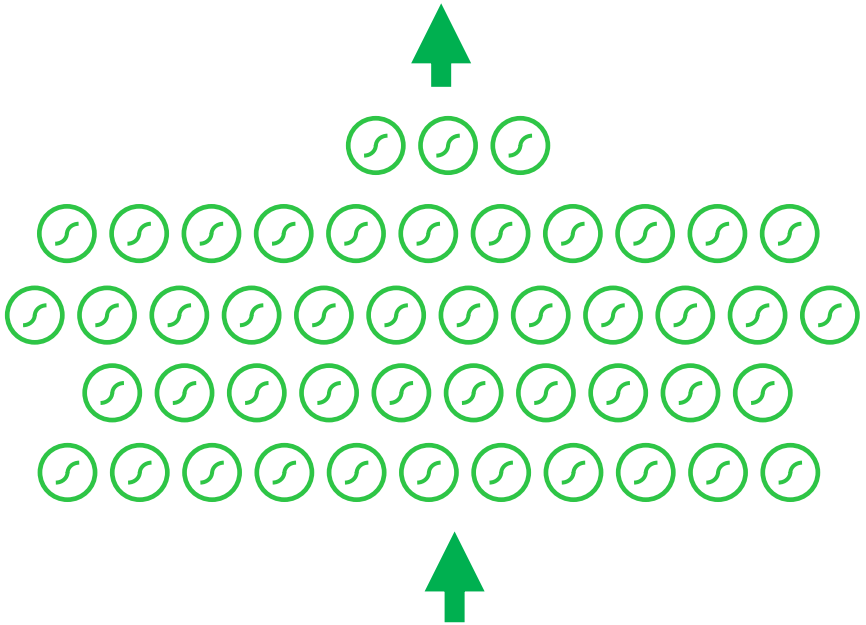

Aktivierungsfunktionen in inneren Schichten

Sigmoid-Funktion

- Siehe Folien/Video zu Neuronen
- Abkürzung: σ
- Bei Logit *z* also Output y:

$$y = \sigma(z) = \frac{1}{1 + e^{-z}}$$

- Wertebereich: 0 < y < 1

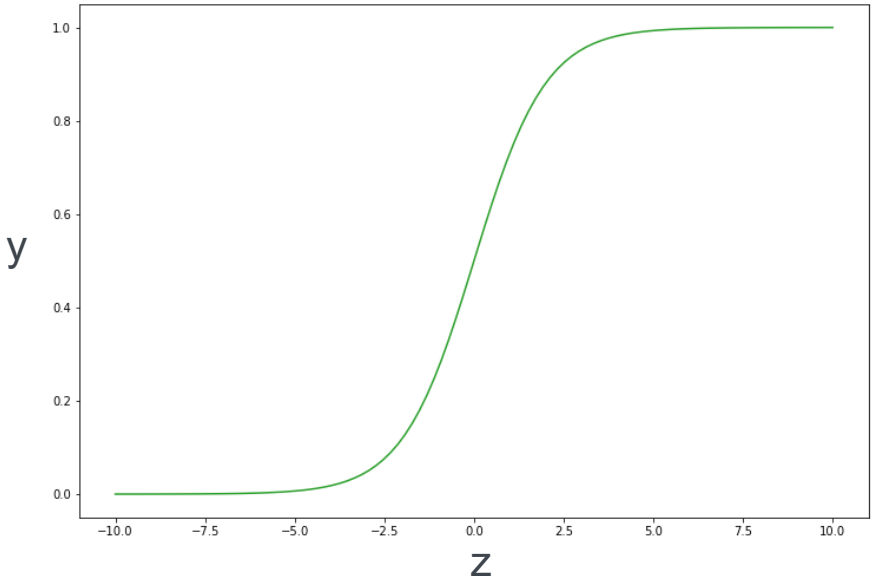

Nicht-Linearität bei Sigmoid-Aktivierung

- Lineare Kombination mehrerer Neuronen mit Sigmoid-Aktivierung

⇒ Modellierung komplexerer Zusammenhänge

- Siehe Neuronen

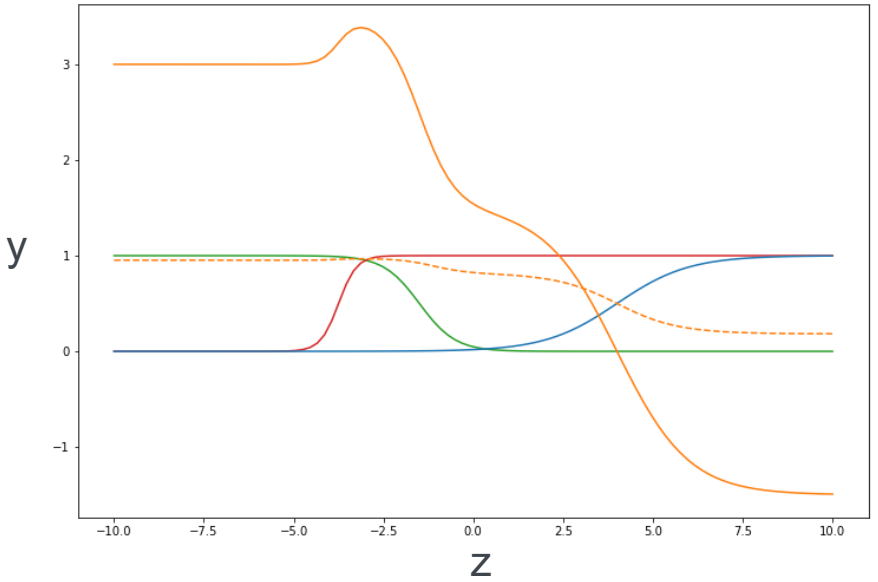

Hyperbeltangens

- Auch: Tangens hyperbolicus
- Abkürzung: $\tanh$
- Bei Logit *z* also Output y:

$$y = \tanh(z) = \frac{e^{z} - e^{-z}}{e^{z} + e^{-z}}$$

- Wertebereich: -1 < y < 1

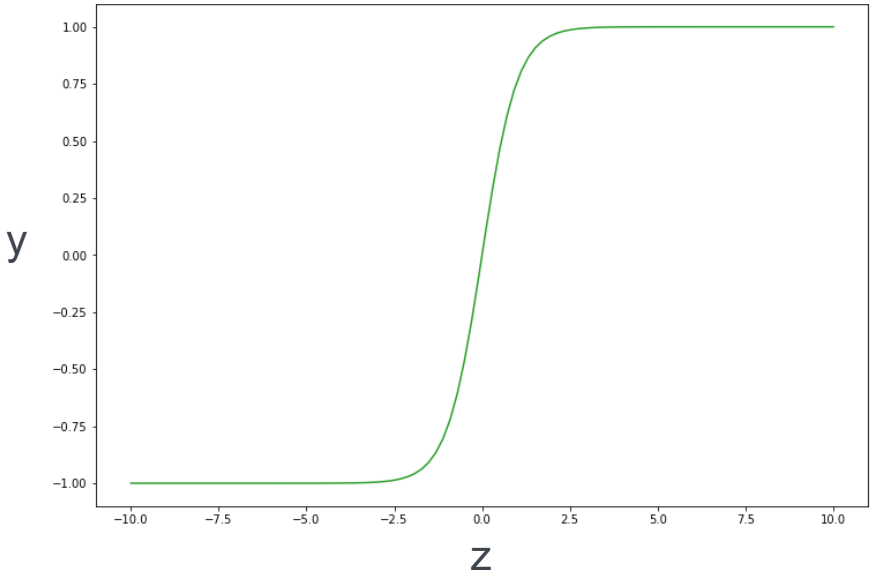

Nicht-Linearität bei Tanh-Aktivierung

- Lineare Kombination mehrerer Neuronen mit Tangens Hyperbolicus-Aktivierung
- Sehr ähnlich zu Sigmoid-Aktivierung

⇒ Modellierung komplexerer Zusammenhänge

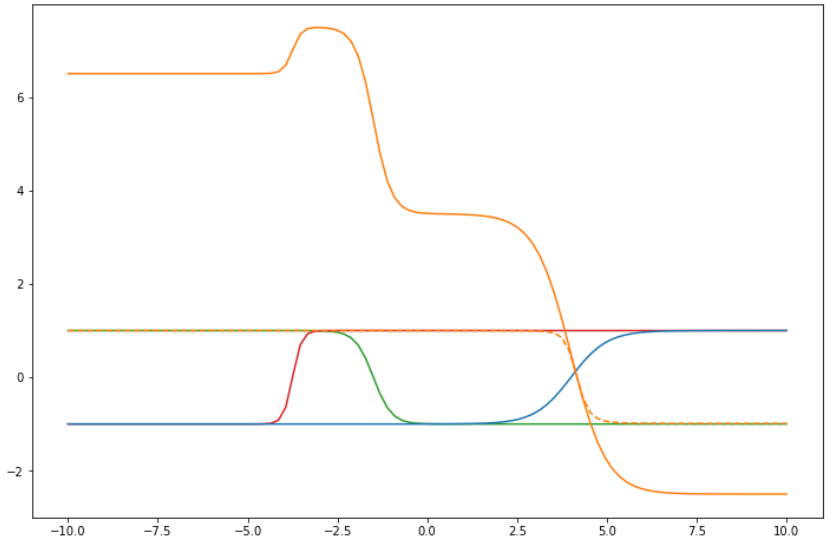

Nachteile von Sigmoid und Hyperbeltangens

- Nicht immer gut geeignet beim Training von tieferen Neuronalen Netzen
- Stichwort: Vanishing Gradient Problem
  - Beide Funktionen sind außerhalb des Bereichs um die 0 sehr flach
  - Beim Training werden die Gewichte im Netzwerk angepasst
  - Mit einem Wert, der mit den Steigungen (engl.: „Gradient“) der Aktivierungsfunktionen der darüber liegenden Schichten multipliziert wurde
  - Wenn die Steigungen sehr klein werden, findet praktisch keine Anpassung mehr statt (Anpassung mit Wert um die Null)
  - Also „lernt“ das Netzwerk an dieser Stelle nicht mehr weiter
  - Vor allem in untersten (frühesten) Ebenen problematisch

Sigmoidfunktion und Hyperbeltangens sind als Aktivierungsfunktionen nur bedingt geeignet.

Bei Netzwerken mit vielen Schichten können sie ein effizientes Training verhindern.

Drag the Words: Sigmoid-Aktivierung

Single Choice: Hyperbeltangens

Multiple Choice: Nachteile von Sigmoid und Hyperbeltangens

Neuere Aktivierungsfunktionen

ReLU Aktivierung

- Eigentlich: Rectifier
- Neuronen mit dieser Aktivierung nennt man „Rectified Linear Units“: ReLU
- $$y = \max(0, z) \quad \text{also} \quad y = \begin{cases} 0 & z < 0 \\ z & z \geq 0 \end{cases}$$
- Stückweise linear
- Kann sogar biologisch motiviert werden
- Heute vorherrschend
- Effizienter beim Training als σ und $\tanh$

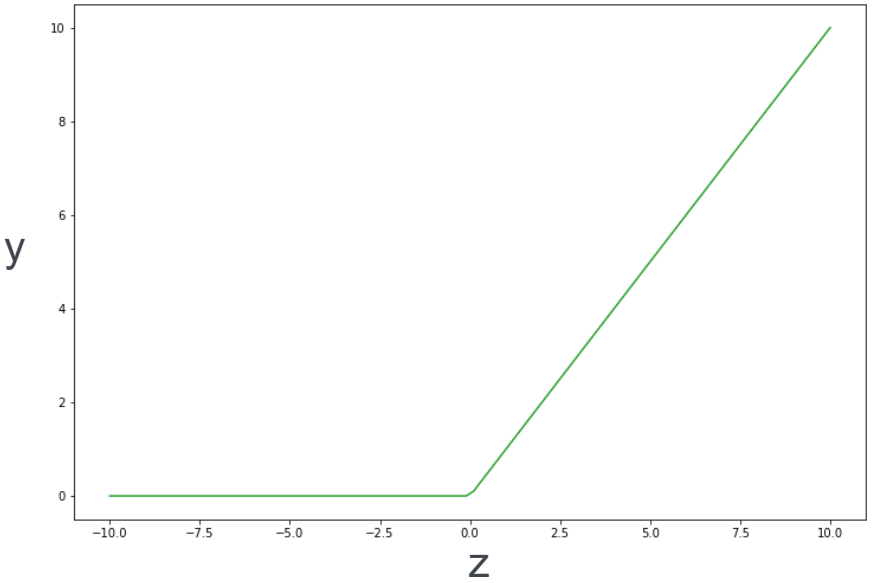

Nicht-Linearität bei ReLU-Aktivierung

- Lineare Kombination mehrerer Neuronen mit ReLU-Aktivierung

⇒ Auch hier Modellierung komplexer nicht-linearer Zusammenhänge möglich

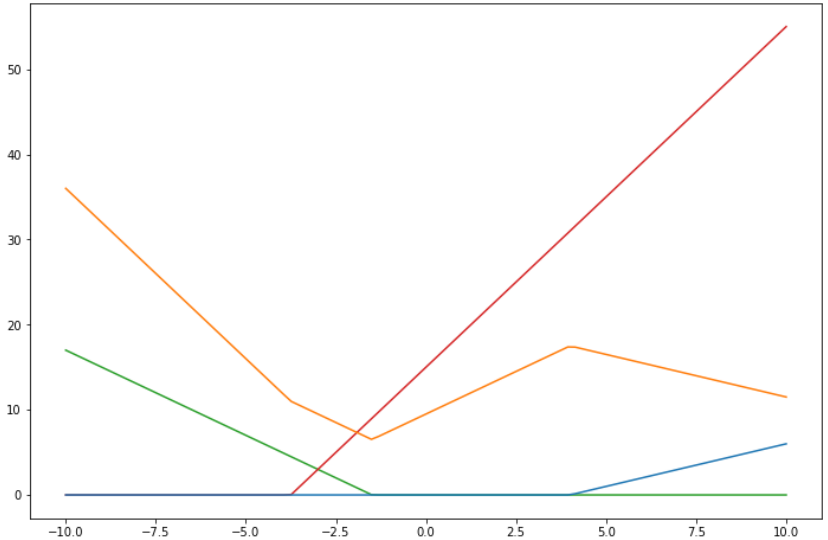

Varianten von ReLU

- Leaky ReLU (“durchlässige ReLU”)
  - $y = \begin{cases} 0.01\,z & z < 0 \\ z & z \geq 0 \end{cases}$
- Parametric ReLU
  - $y = \begin{cases} \alpha\,z & z < 0 \\ z & z \geq 0 \end{cases}$
  - hierbei wird auch α beim Training gelernt

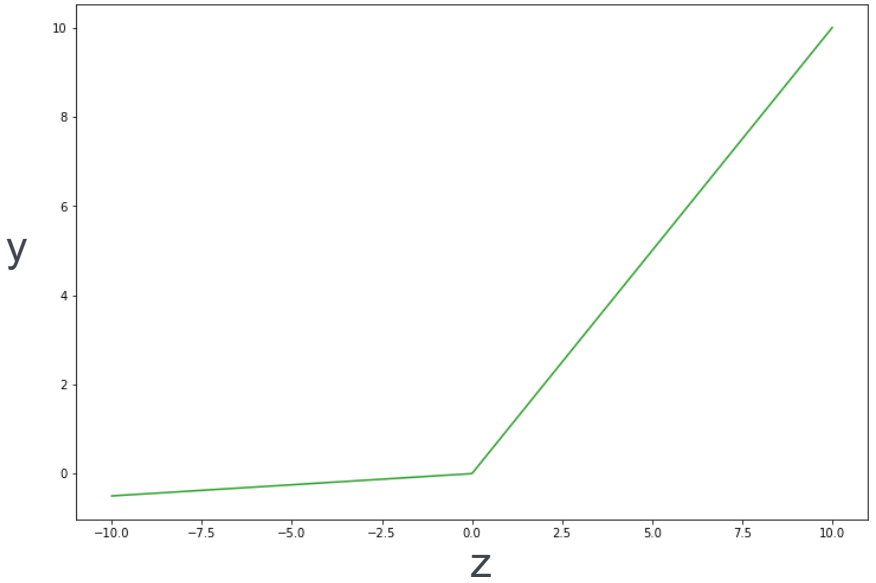

Nicht-Linearität bei Leaky ReLU-Aktivierung

- Lineare Kombination mehrerer Neuronen mit Leaky ReLU-Aktivierung
- Sehr ähnlich zu ReLU

⇒ Auch hier Modellierung komplexer nicht-linearer Zusammenhänge möglich

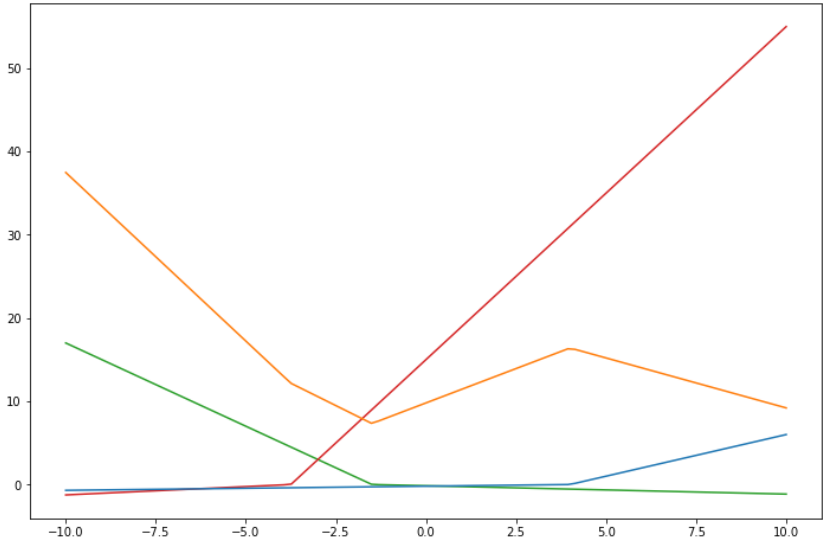

Auch stückweise lineare Aktivierungsfunktionen eignen sich zur Modellierung von Nicht-Linearitäten.

Beispiele sind Rectifier Linear Unit Activation (ReLU-Aktivierung) und deren Varianten.

ReLU-Aktivierung verursacht beim Training weniger Probleme als Sigmoid- oder Tangens Hyperbolicus-Aktivierung.

Drag the Words: ReLU-Aktivierung

Multiple Choice: ReLu-Aktivierung

Aktivierungsfunktionen der letzten Schicht

Ausgabe der letzten Schicht

- Bei mehreren Neuronen in der obersten Schicht handelt es sich meist um Klassifizierung mit mehreren Klassen
- Erwünscht: y_i als Wahrscheinlichkeiten
- d.h. jedes y_i zwischen 0 und 1
- und alle y_i in der Summe 1

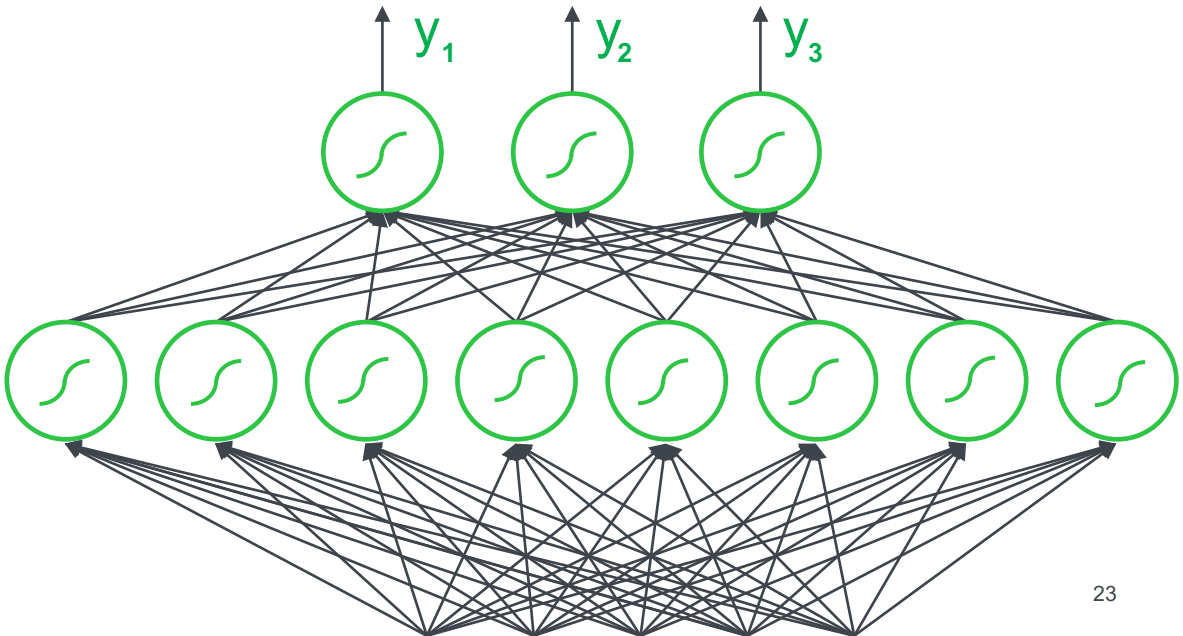

Exponentialfunktion

- Erster Schritt: eine Abbildung, die aus negativen Logits positive Werte macht
- Und deren Steigung (Ableitung) sich möglichst leicht berechnen lässt
- Exponentialfunktion

$$y = e^z$$

- z = -10: y = 0.000045
- z = 10: y = 22026

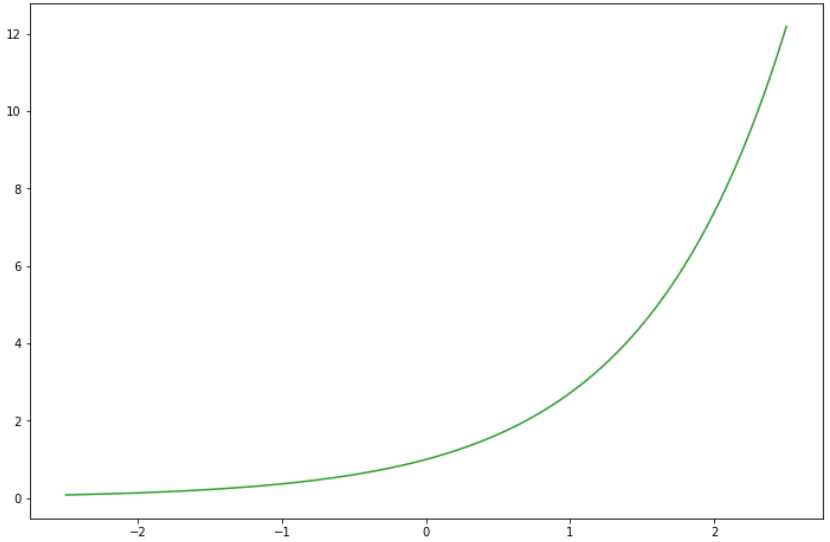

Normalisierung

- Zweiter Schritt:
  - Werte sollen zwischen 0 und 1 liegen
  - und zusammen 1 ergeben

⇒ Teile durch die Summe aller Ausgänge auf dieser Ebene

$$y_2 = \frac{e^{z_2}}{e^{z_1} + e^{z_2} + e^{z_3}} = \frac{e^{z_2}}{\sum_{j=1}^{3} e^{z_j}}$$

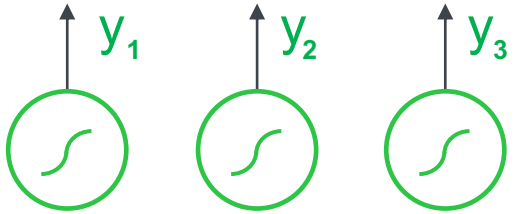

Softmax-Aktivierung

$$y_i = \frac{e^{z_i}}{\sum_{j=1}^{n} e^{z_j}}$$

(y_1 bis y_n Ausgänge, z_1 bis z_n Logits)

Softmax-Aktivierung

$$y_i = \frac{e^{z_i}}{\sum_{j=1}^{n} e^{z_j}}$$

(y_1 bis y_n Ausgänge, z_1 bis z_n Logits)

- Anders als bisherige Aktivierungsfunktionen:
  - Berücksichtigt Logits anderer Neuronen auf derselben Ebene
  - Ergibt Wahrscheinlichkeitsverteilung über alle möglichen Klassen
  - Sinnvoll für Klassifikationsprobleme

Bei Klassifikationsproblemen verwendet man in der letzten Schicht meist Softmax-Aktivierung.

Dadurch ergeben die Ausgaben der letzten Schicht eine Wahrscheinlichkeitsverteilung über die Klassen.

Drag the Words: Die letzte Schicht

INNOVET

KI B³

Künstliche Intelligenz in die berufliche Bildung bringen

Dr. Antje Schweitzer

Universität Stuttgart
Institut für Maschinelle Sprachverarbeitung

Universität Stuttgart
Institut für Maschinelle Sprachverarbeitung
Institut für Software Engineering

IHK Industrie- und Handelskammer Reutlingen
Reutlingen | Tübingen | Zollernalb

IHK Region Stuttgart

IHK Industrie- und Handelskammer Karlsruhe

LMU Ludwig-Maximilians-Universität München

GEFÖRDERT VOM

INNOVET

Bundesministerium für Bildung und Forschung

bibb Bundesinstitut für Berufsbildung

Gefördert als InnoVET-Projekt aus Mitteln des Bundesministeriums für Bildung und Forschung.

Lizenzbestimmungen

“Aktivierungsfunktionen" von Antje Schweitzer, KI B³ / Uni Stuttgart

Das Werk - mit Ausnahme der folgenden Elemente:

- Logos der Verbundpartner und des Förderprogramms
- im Quellenverzeichnis aufgeführte Medien

ist lizenziert unter:

 CC BY 4.0 (https://creativecommons.org/licenses/by/4.0/deed.de)
(Namensnennung 4.0 International)

Quellenverzeichnis

Titelfoto: Jean-Philippe Delberghe (https://unsplash.com/@jipy32), ohne Titel, auf Unsplash (https://unsplash.com/photos/75xPHEQBmvA), ist lizenziert unter Unsplash-Lizenz (https://unsplash.com/license). Bildausschnitt verändert.