



Neuronale Netze und Algorithmen

Modellierung dynamischer und adaptiver Systeme
WS 2017/18

Njomza Avdijaj

18. Januar 2018

Software and Systems Engineering

Agenda

1. Motivation
2. Grundlagen
3. Netztypen
4. Lernstrategien
5. Deep Learning
6. Anwendungen
7. Zusammenfassung
8. Quellen

Motivation

- **Berechnungsmodell** mit biologischem Vorbild
- **Interdisziplinärer Forschungsgegenstand** der Informatik, Mathematik, Biologie und Physik
- **Pionierleistungen** der Forscher **Warren McCulloch** und **Walter Pitts** im Jahr **1943**


Grundlagen

Neuronen und Verbindungen

Gerichteter Graph $G = (U, C)$

$U \rightarrow$ Units \rightarrow Neuronen

$C \rightarrow$ Connections \rightarrow Verbindungen



<http://web.utk.edu/~wfeng1/spark/fnn.html>

Schichten

- **Input Layer:**

Neuronen können von der Außenwelt Informationen empfangen

- **Output Layer:**

Neuronen können Informationen an die Außenwelt weitergeben

- **Hidden Layer:**

- Neuronen ohne Kontakt zur Außenwelt
- Interne Repräsentation

Jede Kante $(v, u) \in C$ trägt ein **Gewicht** w_{uv}

→ Stärke der Verbindung zwischen dem sendenden Neuron v und dem empfangenden Neuron u

Positives Gewicht ($w_{uv} > 0$) → exzitatorischer, erregender Einfluss

Negatives Gewicht ($w_{uv} < 0$) → inhibitorischer, hemmender Einfluss




Gewicht von Null ($w_{uv} = 0$) → kein Einfluss

Definition

Das **Wissen** eines neuronalen Netzes ist in seinen Gewichten gespeichert.

Lernen wird als Gewichtsveränderung zwischen den Neuronen definiert.

Funktionsweise von Neuronen



$$y1 = w_{11}x_1 + w_{12}x_2 + w_{13}x_3$$

<https://cloud.google.com/blog/big-data/2017/05/an-in-depth-look-at-googles-first-tensor-processing-unit-tpu>

Funktionsweise von Neuronen

$$y_1 = f(w_{11}x_1 + w_{12}x_2 + w_{13}x_3)$$

↑
activation function

$$y_1 = f(w_{11}x_1 + w_{12}x_2 + w_{13}x_3)$$
$$y_2 = f(w_{21}x_1 + w_{22}x_2 + w_{23}x_3)$$

<https://cloud.google.com/blog/big-data/2017/05/an-in-depth-look-at-googles-first-tensor-processing-unit-tpu>

Zusammenfassung:

1. Berechnung der einzelnen Inputs
2. Berechnung des Netziinputs mithilfe der einzelnen Inputwerte
3. Zuordnung des Netziinputs zu einem Aktivitätslevel

Funktionen

Input

$$input_{uv} = a_v \cdot w_{uv}$$

Netinput

$$netinput_u = \sum_v input_{uv} = \sum_v a_v \cdot w_{uv}$$


Aktivitätsfunktion




Linear-Funktion



Schwellwert-Funktion




Sigmoid-Funktion



Tangenshyperbolikus-Funktion

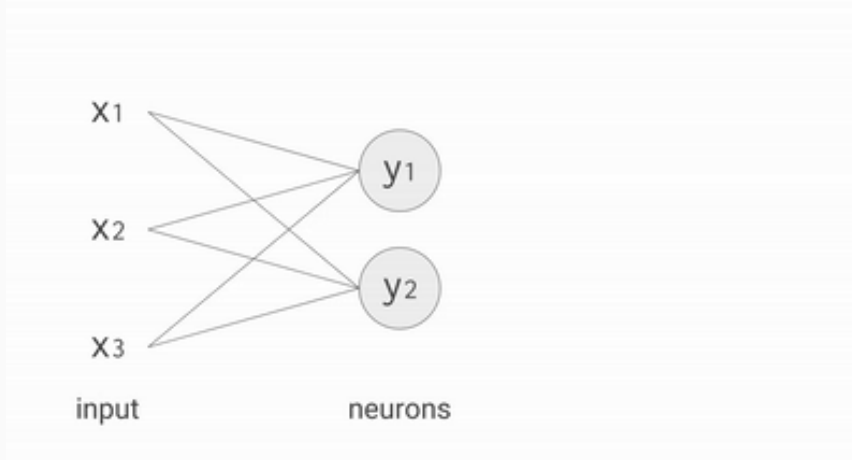
<http://www.electroyou.it/nunziox/wiki/un-esempio-di-rete-neurale-a-percettore-multistrato>

Gewichtsmatrix



<http://www.neuronalesnetz.de/matrix.html>

Berechnung



$$y1 = f(w_{11}x_1 + w_{12}x_2 + w_{13}x_3)$$
$$y2 = f(w_{21}x_1 + w_{22}x_2 + w_{23}x_3)$$


<https://cloud.google.com/blog/big-data/2017/05/an-in-depth-look-at-googles-first-tensor-processing-unit-tpu>

Berechnung durch Multiplikation der **Gewichtsmatrix** mit dem **Inputvektor**:

$$\begin{pmatrix} w_{11} & w_{12} & w_{13} \\ w_{21} & w_{22} & w_{23} \end{pmatrix} \cdot \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = \begin{pmatrix} w_{11}x_1 + w_{12}x_2 + w_{13}x_3 \\ w_{21}x_1 + w_{22}x_2 + w_{23}x_3 \end{pmatrix}$$

Netztypen

Feedforward Neural Networks



Kruse, R., Borgelt, C., Klawonn, F., Moewes, C., Steinbrecher, M., and Held, P. (2013). **Computational Intelligence: A Methodological Introduction**. Springer Publishing Company, Incorporated.

Definition

Ein **Multilayer Perceptron** (R -Layer Perceptron) ist ein gerichteter Graph $G = (U, C)$, für den Folgendes gilt:

- eine Eingabe- und eine Ausgabeschicht
- $r - 2$ verdeckte Schichten
- Verbindungen nur zwischen aufeinanderfolgenden Schichten

Definition

Ein **Recurrent Neural Network** ist dadurch gekennzeichnet, dass **Rückkopplungen** von Neuronen einer Schicht zu anderen Neuronen derselben oder einer vorangegangenen Schicht existieren.

Rückkopplungsarten

- Direkte Rückkopplungen
- Indirekte Rückkopplungen
- Seitliche Rückkopplungen
- Vollständige Verbindungen

Lernstrategien

Supervised vs Unsupervised

Supervised Learning → *labeled training data*

- Vorgabe der gewünschten Ausgabe zu verschiedenen Eingabemustern
- Vergleich der tatsächlichen mit der vorgegebenen Ausgabe
- Anpassung der Gewichte zur Minimierung des Fehlers

⇒ *Backpropagation*

Unsupervised Learning → *unlabeled training data*

- Vorgabe der zu lernenden Eingabemuster ohne Zielwert
- Lernen durch Mustererkennung und Vergleich der Eingabedaten
- Gewichtsanzpassung zur Erzeugung ähnlicher Ausgaben für ähnliche Eingaben

1. Forward-Pass:

- Berechnung der Netzausgabe für jedes Eingabemuster

2. Fehlerbestimmung:

- Vergleich der tatsächlichen mit der gewünschten Ausgabe durch eine Fehlerfunktion

- $$E = \sum_{I \in \mathcal{I}} \sum_{v \in \mathcal{U}_{out}} e_v^{(I)} = \sum_{I \in \mathcal{I}} \sum_{v \in \mathcal{U}_{out}} (t_v^{(I)} - o_v^{(I)})^2$$

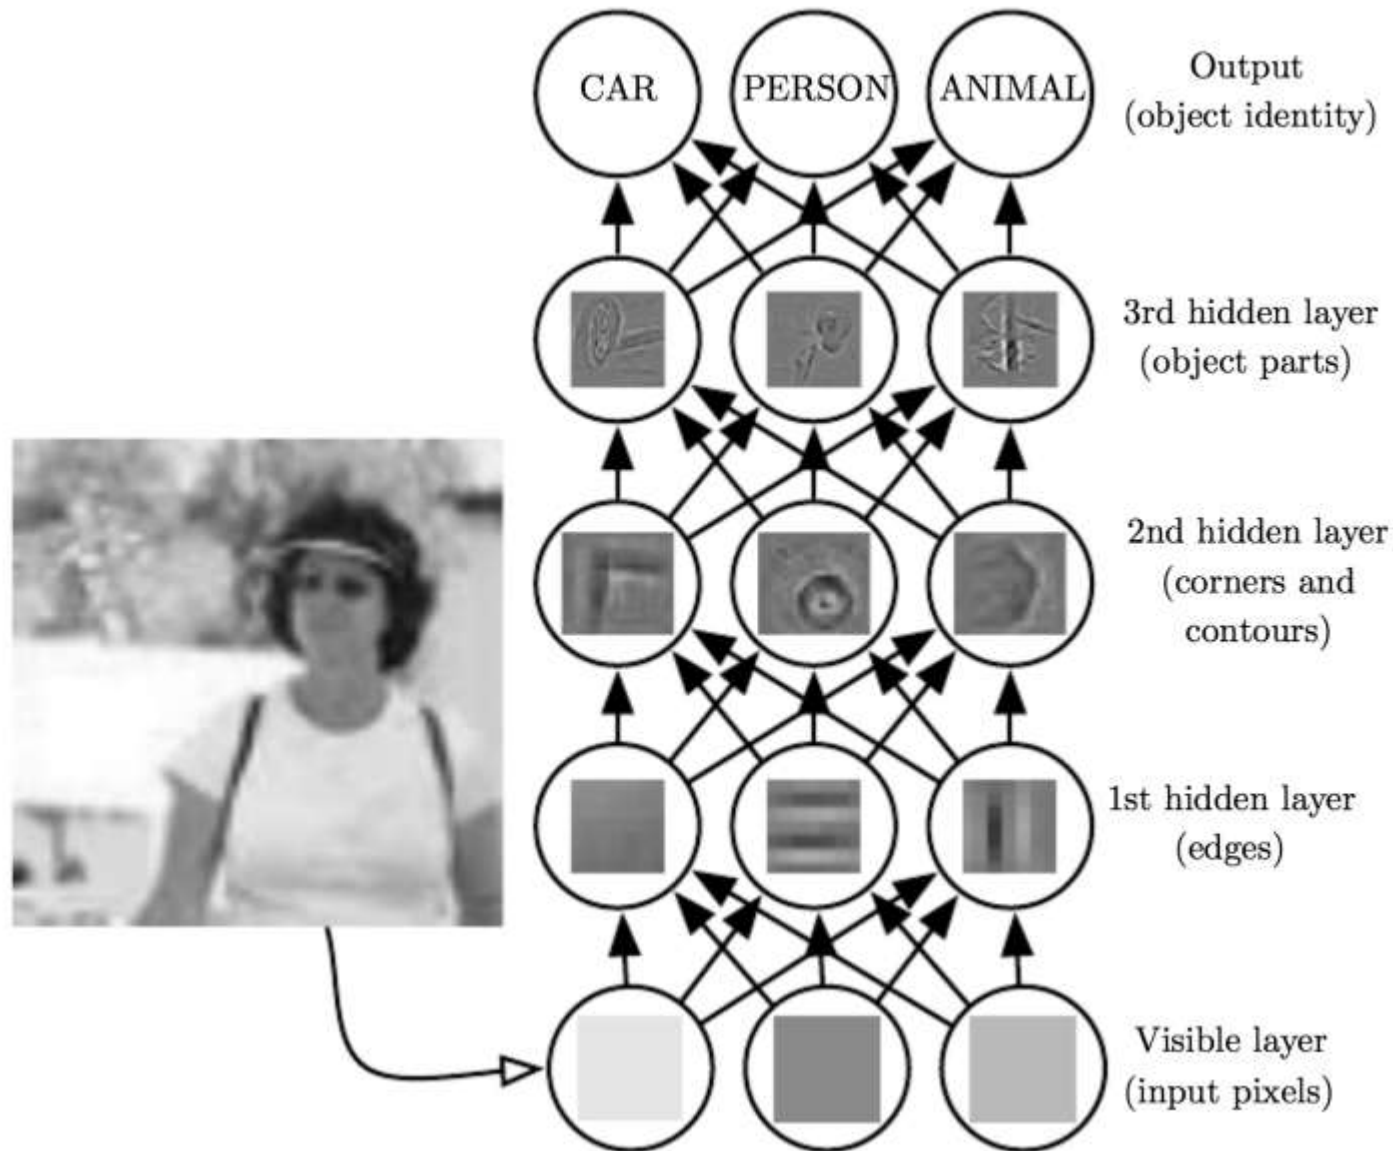
3. Backward-Pass:

- Fehlerrückführung von der Ausgabe- bis hin zur Eingabeschicht
- Anpassung der Gewichte abhängig von ihrem Einfluss auf den Fehler
- Minimierung des Gesamtfehlers

Deep Learning

- Klasse von Optimierungsmethoden künstlicher neuronaler Netze
- Netze mit einer tiefen inneren Struktur (zahlreiche Hidden Layer)
- Lösung von Problemen, die nicht formal beschrieben werden können
- Intuitives Wissen
- Lernen aus Erfahrung
- Hierarchie von Konzepten
- Steigerung des Abstraktionslevels von Schicht zu Schicht

Beispiel



<http://www.deeplearningbook.org/contents/intro.html>

Anwendungen

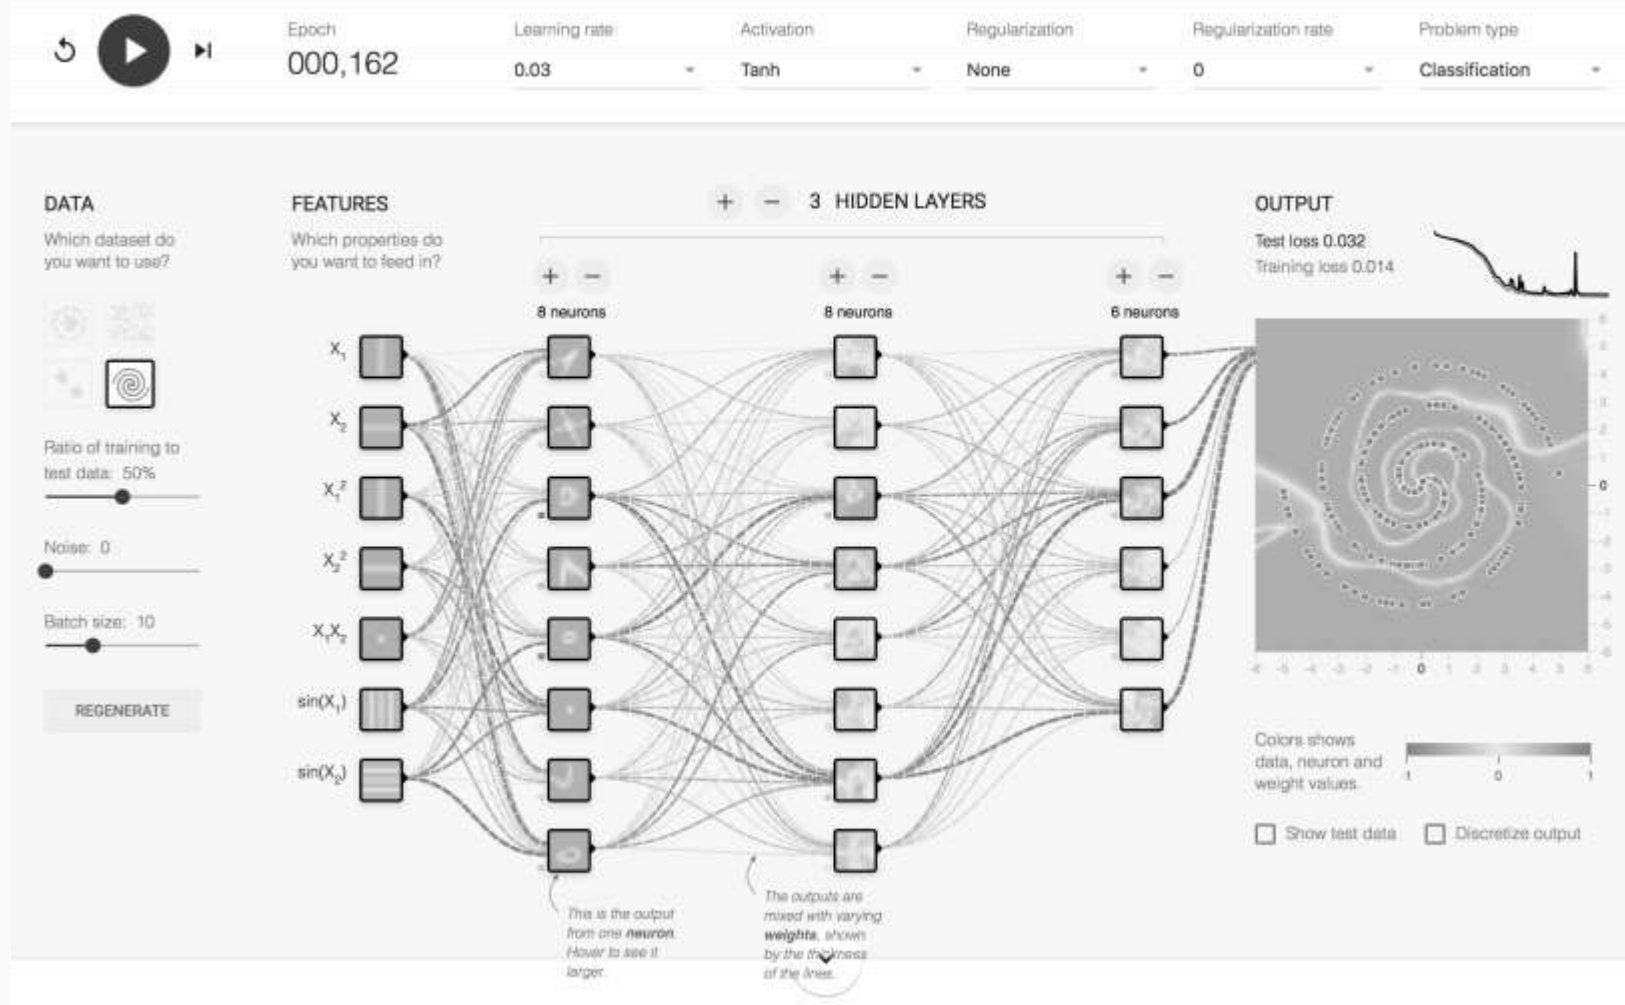
Anwendungsgebiete

Anwendungen, bei denen kein oder nur geringes explizites Wissen über das zu lösende Problem vorliegt:

- Bildverarbeitung und Mustererkennung
 - Bilderkennung
 - Texterkennung
 - Schrifterkennung
 - Gesichtserkennung
 - Spracherkennung
 - Maschinenübersetzung
- Klassifikation
- Optimierung
- Medizinische Diagnostik
- Frühwarnsysteme
- Robotik
- Virtuelle Agenten

- Verschiedene Bibliotheken
 - TensorFlow (<https://www.tensorflow.org>)
 - Keras (<https://keras.io>)
- Tools
 - Neural Network Toolbox
(<https://de.mathworks.com/products/neural-network.html>)
 - Stuttgarter Neural Network Simulator
(<http://www.ra.cs.uni-tuebingen.de/SNNS/>)
 - Simbrain (<http://simbrain.net>)

TensorFlow Playground



<http://playground.tensorflow.org>

Zusammenfassung

Zusammenfassung

Neuronale Netze bekommen eine Struktur und ein Lernverfahren vorgegeben und müssen dann in einem Lernprozess selber die richtige Konfiguration zur Lösung eines Problems finden.

Probleme

- Sammlung oder manuelle Erzeugung von Trainings- und Testdaten notwendig
- Großer Rechenaufwand
- Möglicherweise keine optimale Lösung (lokales statt globales Optimum)
- Overfitting (keine Verallgemeinerung auf neue Daten möglich)
- Blackbox bei umfangreicher innerer Struktur
- Fragwürdige biologische Plausibilität

Quellen

Goodfellow, I., Bengio, Y., and Courville, A. (2016). Deep Learning. MIT Press. Online erhältlich unter <http://www.deeplearningbook.org>; 15. Januar 2018.

Kruse, R., Borgelt, C., Klawonn, F., Moewes, C., Steinbrecher, M., and Held, P. (2013). Computational Intelligence: A Methodological Introduction. Springer Publishing Company, Incorporated.

Nielsen, M. A. (2015). Neural Networks and Deep Learning. Online erhältlich unter <http://neuralnetworksanddeeplearning.com>; 8. Januar 2018.

Rey, G. and Wender, K. (2011). Neuronale Netze: eine Einführung in die Grundlagen, Anwendungen und Datenauswertung. Aus dem Programm Huber:Psychologie-Lehrbuch. Huber. Online erhältlich unter <http://www.neuralesnetz.de>; 14. Januar 2018.

Rojas, R. (1993). Theorie der neuronalen Netze: eine systematische Einführung. Springer Lehrbuch. Springer.

Sato, K. (2016). Understanding neural networks with TensorFlow Playground. Online erhältlich unter <https://cloud.google.com/blog/big-data/2016/07/understanding-neural-networks-with-tensorflow-playground>; 15. Januar 2018.

Sato, K., Young, C., and Patterson, D. (2017). An in-depth look at Google's first Tensor Processing Unit (TPU). Online erhältlich unter <https://cloud.google.com/blog/big-data/2017/05/an-in-depth-look-at-googles-first-tensor-processing-unit-tpu>; 4. Januar 2018.

Smilkov, D. and Carter, S. TensorFlow Playground. Online erhältlich unter <http://playground.tensorflow.org/>; 15. Januar 2018.

Fragen?