



Wissensentdeckung in Datenbanken

Deep Learning

Nico Piatkowski und Uwe Ligges

Informatik—Künstliche Intelligenz
Computergestützte Statistik
Technische Universität Dortmund

20.07.2017

Überblick

- Künstliche Neuronale Netze

- Motivation
- Formales Modell
- Aktivierungsfunktionen
- Vorhersage
- Parameterschätzung


- Varianten

- Faltungsnetze
- Rekurrente Netze
- Autoencoder






Motivation






Motivation



Motivation (Deep Vs. Not-Deep)




Beispiel für “Eingabeneuronen” (x): Pixel (Farbwerte) einer Bilddatei, Wortvektoren (bag-of-words, TF-IDF), ...

Formalisierung

Künstliches Neuronales Netz f :

- Graph $G = (V, E)$. Knoten heißen **Neuronen**
- Jedes Neuron liegt in einer **Schicht**
 $L : V \rightarrow \{0, 1, 2, \dots, K\}$,
- Eine **Aktivierungsfunktion** pro Knoten: $a_v : \mathbb{R} \rightarrow \mathbb{R}, \forall v \in V$
- Schicht 0 heißt **Eingabeschicht**, Schicht K heißt **Ausgabeschicht**



Jedes Neuron v auf Schicht $k > 0$ (d.h. $L(v) = k$) repräsentiert eine Funktion $v : \mathcal{X}_v \rightarrow \mathcal{Y}_v$:


- Eingabe ist eine gewichtete Summe der Ausgaben aller Neuronen auf Schichte $k - 1$
- Ausgabe ist eine Reelle Zahl



Formalisierung

Künstliches Neuronales Netz f :

- Graph $G = (V, E)$. Knoten heißen **Neuronen**
- Jedes Neuron liegt in einer **Schicht**
 $L : V \rightarrow \{0, 1, 2, \dots, K\}$,
- Eine **Aktivierungsfunktion** pro Knoten: $a_v : \mathbb{R} \rightarrow \mathbb{R}, \forall v \in V$
- Schicht 0 heißt **Eingabeschicht**, Schicht K heißt **Ausgabeschicht**



Jedes Neuron v auf Schicht $k > 0$ (d.h. $L(v) = k$) repräsentiert eine Funktion $v : \mathcal{X}_v \rightarrow \mathcal{Y}_v$:

- Eingabe ist eine gewichtete Summe der Ausgaben aller Neuronen auf Schichte $k - 1$
- Ausgabe ist eine Reelle Zahl



Formalisierung (II)

Jedes Neuron v auf Schicht $L(v) > 0$ repräsentiert eine Funktion $v : \mathcal{X}_{k-1} \rightarrow \mathcal{X}_v$

Notation: Ausgabe von Neuron v ist $\text{out}(v)$.

$$\text{out}(v) = a_v \left(\sum_{w:L(w)=L(v)-1} \beta_{vw} \text{out}(w) \right)$$

- \mathcal{X}_{k-1} ist der gemeinsame Ausgaberaum aller Neuronen auf Ebene $k - 1$
- \mathcal{X}_v ist der Ausgaberaum von v
- Dann ist das gesamte Netz eine Funktion $f : \mathcal{X}_0 \rightarrow \mathcal{X}_K$

Aktivierungsfunktionen an Neuron $v \in V$

Sigmoid:




$$a_v^{\text{sig}}(z) = \frac{1}{1 + \exp(-z)}$$

Tangens Hyperbolicus (tanh):

$$a_v^{\text{tanh}}(z) = \frac{\exp(z) - \exp(-z)}{\exp(z) + \exp(-z)}$$

Rectified linear unit (ReLU):

$$a_v^{\text{ReLU}}(z) = \max\{0, z\}$$



Parameter lernen

Neuronales Netz ist eine Modellfunktion f .

Grundsätzlich sind alle aus der Vorlesung bekannten Verlustfunktionen $\ell(f, \mathcal{D})$ möglich.


Allgemein:

- Die Anzahl der Parameter eines Neurons v ist gleich der Anzahl der Neuronen in Schicht $L(v) - 1$
- Berechnung des Gradienten $\nabla \ell(f, \mathcal{D})$ durch Anwendung der Kettenregel (Backpropagation)
- Optimierung mittels stochastischem Gradientenabstieg

$$\beta^{t+1} = \beta^t + \eta \nabla \ell(\beta^t, S)$$

$S \subset \mathcal{D}$, Extremfall: $S = \{(\mathbf{x}, \mathbf{y})\}$ (nur ein Datenpunkt pro Gradientenschritt)

Beispiel: "AlexNet"



- Gewinner der ImageNet 2012 Challenge

Repräsentationslernen mittel Faltung




Abbildung: Gelernte Filter in AlexNet Schicht “Conv1”: Gabor Filter & Color Blobs

Beobachtung: Tiefe des Netzes erhöht Abstraktionsgrad der internen Representation

- Erste Schichten: **Allgemein**, lokale Representation
- Tiefe Schichten: **Spezifisch**, globale Representation