

## 8. Übungsblatt

### Aufgabe 32 Visualisierung von Gewichten

Betrachten Sie folgende Funktion  $f(x) = \text{relu}(xW)$ , wobei  $x = (x_1, x_2, x_3, x_4, x_5)$  und

$$W = \begin{bmatrix} 1 & 0 & 0 & 0 \\ -1 & 1 & 0 & 0 \\ 0 & -1 & 1 & 0 \\ 0 & 0 & -1 & 1 \\ 0 & 0 & 0 & -1 \end{bmatrix}$$

Initialisieren Sie  $x = 0$  und maximieren Sie den zweiten Spaltenvektor  $(xW)_1$  mit Gradientenaufstieg für zwei Schritte mit einer Lernrate von 1.

- Interpretieren Sie, was das Ergebnis des Gradientenaufstiegs zeigt.
- Betrachten Sie die Berechnung von  $xW$ . Überlegen Sie, bei welcher Architektur Sie diese Art von Berechnung bereits gesehen haben.

### Aufgabe 33 Fehlerfunktionen und wie sie zu finden sind

Beim Trainieren von neuronalen Netzen können unterschiedliche Fehlerfunktionen verwendet werden. Dabei werden in der Regel Parameter  $\theta$  gesucht die  $J(\theta) = \mathbb{E}_{x,y \sim p} \log(P(y|x; \theta))$  maximieren. Also den Erwartungswert, dass der richtige Wert  $y$  eine hohe Wahrscheinlichkeit gegeben dem zugehörigen Wert  $x$  hat. Dieses Verfahren nennt sich Maximum-Likelihood Schätzer.

In einer Regressionsaufgabe ist  $P(y|x; \theta) = \mathcal{N}(y, f(x; \theta), 1)$ , wobei  $\mathcal{N}(y, \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp(-\frac{(y-\mu)^2}{2\sigma^2})$ . Das bedeutet, dass die Wahrscheinlichkeit hoch ist, wenn der Zielwert nah an dem vorhergesagten Wert ist

- Ermitteln Sie die zu optimierende Funktion, wenn wir gegebenes  $P(y|x; \theta)$  nehmen und  $J(\theta)$  maximieren wollen.
- Erklären Sie, wie sich die Fehlerfunktion verhält, wenn der Fehler besonders groß oder besonders klein wird

**Aufgabe 34 Fehlerfunktion: Kreuzentropie**

Gegeben sei ein Datensatz von Bildern von fünf verschiedenen Tieren. Jedes Bild zeigt genau ein Tier. Jedes Bild hat zudem ein Label  $P$ , welches das abgebildete Tier als One-Hot-Kodierung wie folgt angibt:

Tier	Label
Hund	[1 0 0 0 0]
Katze	[0 1 0 0 0]
Pferd	[0 0 1 0 0]
Adler	[0 0 0 1 0]
Kuh	[0 0 0 0 1]

- Wofür ist die Entropie bzw. die Kreuzentropie im allgemeinen ein Maß? Warum und wie können wir dies für Neuronale Netze nutzen?
- Nehmen Sie an ein Netz, das auf diesen Daten trainiert, generiert für das Bild eines Hundes die Ausgabe  $Q1 = [0.45 \ 0.25 \ 0.03 \ 0.07 \ 0.2]$ . Berechnen Sie die Kreuzentropie  $H(P,Q1)$ . Das Netz klassifiziert das Bild korrekt als Hund. Warum ist die Ausgabe trotzdem problematisch?
- Das Netz hat nun eine längere Zeit trainiert und generiert für das selbe Bild die Ausgabe  $Q2 = [0.97 \ 0.1 \ 0.03 \ 0.07 \ 0.1]$ . Berechnen Sie erneut die Kreuzentropie  $H(P,Q2)$ . Was können wir basierend auf diesen Werten über unser Netz aussagen?

**Aufgabe 35 Aktivierungsfunktion: Softmax**

Im überwachten Lernen ist ein häufiger Anwendungsfall die Klassifikation. Ein typisches Beispiel ist die Klassifikation von Bildern wie beispielsweise in der ILSVRC vom <http://www.image-net.org/>. Um diese Aufgabe zu lösen eignen sich unsere bisherigen Fehlerfunktionen nicht. Dafür wird erneut eine Maximum-Likelihood Schätzung verwendet:  $\max_{\theta} \mathbb{E}_{x,c \sim p} \log(P(y = c|x; \theta)) \Leftrightarrow \min_{\theta} \mathbb{E}_{x,c \sim p} -\log(P(y = c|x; \theta))$

Für Klassifikationsprobleme wird in der Regel die Softmaxfunktion als  $f_{act}$  verwendet.

$$softmax(z)_i = \frac{\exp(z_i)}{\sum_j \exp(z_j)}$$

- Nehmen Sie an, dass wie in Aufgabe 34 Bilder von fünf verschiedenen Tieren als Datensatz genutzt werden. Die Ausgabe des Netzes sei wie folgt:

Eingabebild	Ausgabe $y_i$
Katze	[6 5 2 3 1]
Pferd	[4 3 8 1 -2]
Pferd	[4 4 1 -1 0]

Berechnen Sie den Softmax der Ausgaben. Warum wird der Softmax der Ausgabe und nicht die direkte Ausgaben zur Klassifikation eingesetzt?

- Softmax wird oft in Verbindung mit der negativen Log-Likelihood Funktion  $L(y) = \mathbb{E}_{x,c \sim p} -\log(P(y = c|x; \theta))$  als Fehlerfunktion verwendet. Berechnen Sie  $-\log(\text{softmax}(z)_i)$ . Welche Eigenschaft sorgt dafür, dass der Fehler einen hilfreichen Gradienten liefern kann ?