



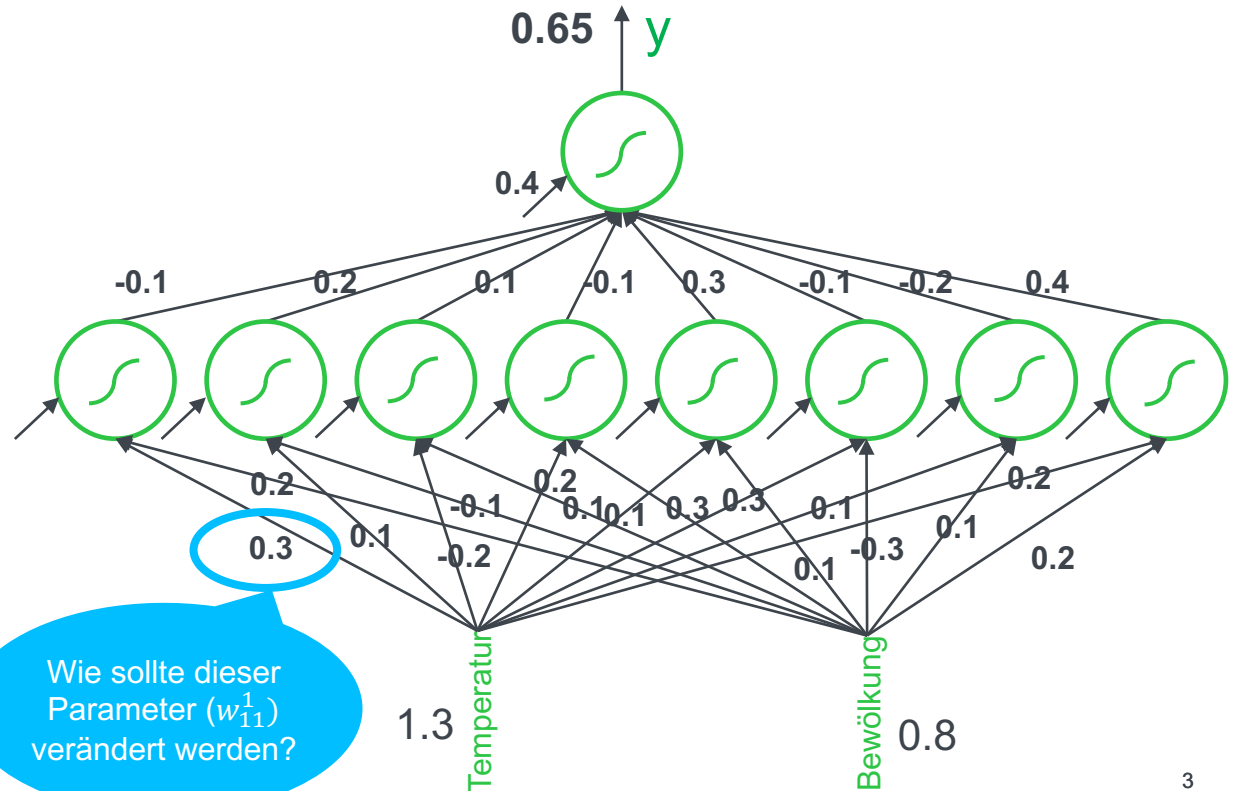
Verlustfunktion

Die Zielvorgabe fürs Training


Rückblick: Training neuronaler Netze

Folie aus: Training von neuronalen Netzen


- Mit diesen Parametern:
 - Bei Input 1.3, 0.8
 - Ergebnis 0.65
- Abgleich mit korrektem Ergebnis:
 - Korrektes Ergebnis 0.45
 - „Verlust“ (Fehler): 0.2
- Gesucht:
 - Bessere Parameter
 - D.h. mit kleinerem Fehler




Folie aus: Training von neuronalen Netzen



Steigung stark negativ



Steigung schwach negativ



Steigung positiv

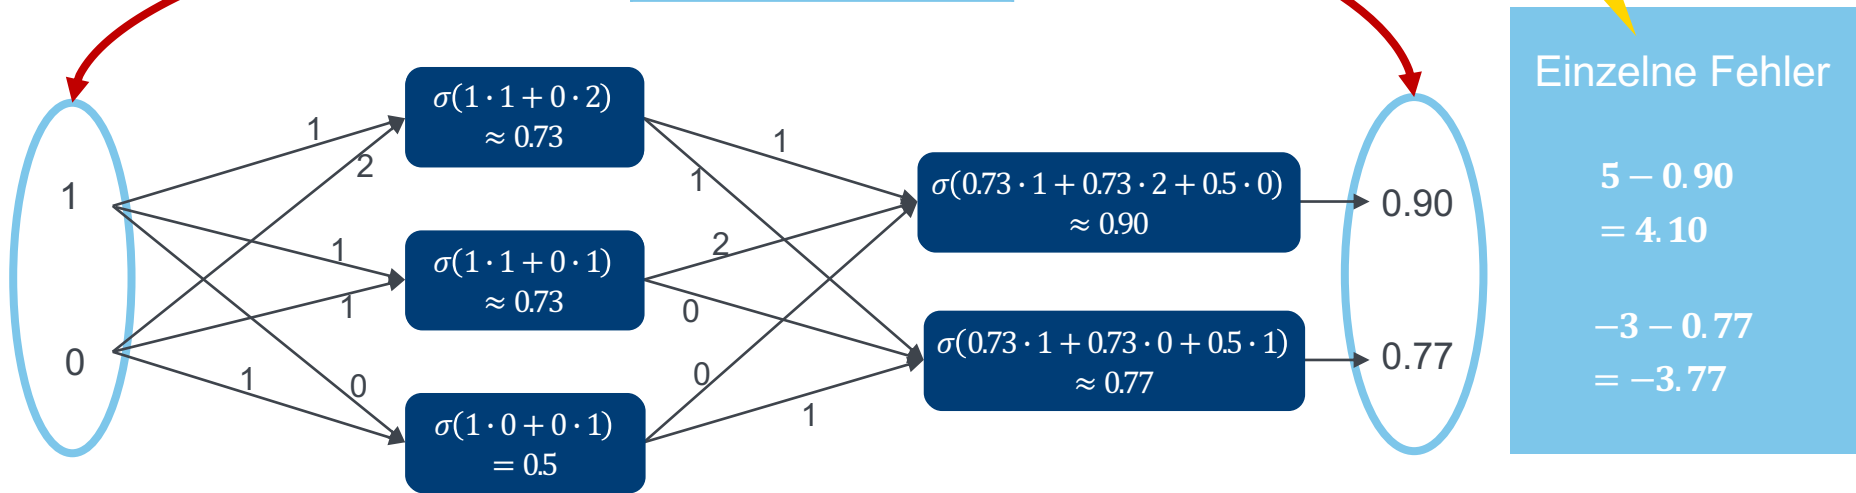
Verlustfunktion bei Regressionsproblemen

Beispiel – Netzwerk* für Regression

- Trainingsdatenpunkt:

Input	Ergebnis
1	5
0	-3

Ziel: Fehler
möglichst
klein!



Verlust bei Regression

- Idee: wie bei Evaluationsmaßen für Regression
- Quadriere Einzelfehler, bilde Mittelwert
- Mean Squared Error, MSE
- Vorteile:
 - Positive und negative Fehler heben sich nicht gegenseitig auf
 - Größere Fehler werden stärker bestraft

Einzelne Fehler

$$5 - 0.90 \\ = 4.10$$

$$-3 - 0.77 \\ = -3.77$$

Summe
0.33

MSE

$$\frac{1}{2} \cdot 4 \cdot 10^2$$

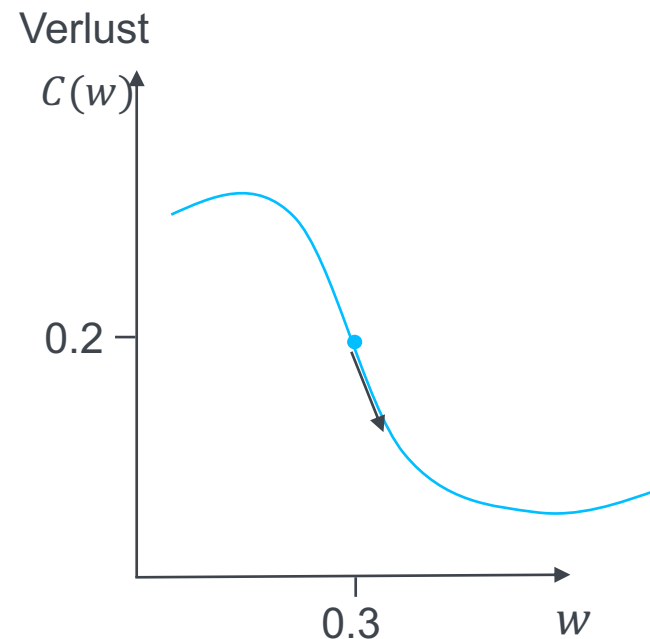
$$+ \frac{1}{2} \cdot (-3.77)^2$$

Summe
15.5

Vom Fehler zur Verlustfunktion

- Beim Training interessant:
 - Wie verändert sich der Verlust, wenn die Gewichte verändert werden?
 - Verlust in Abhängigkeit von den Parametern des Netzwerks
 - Verlust als Funktion

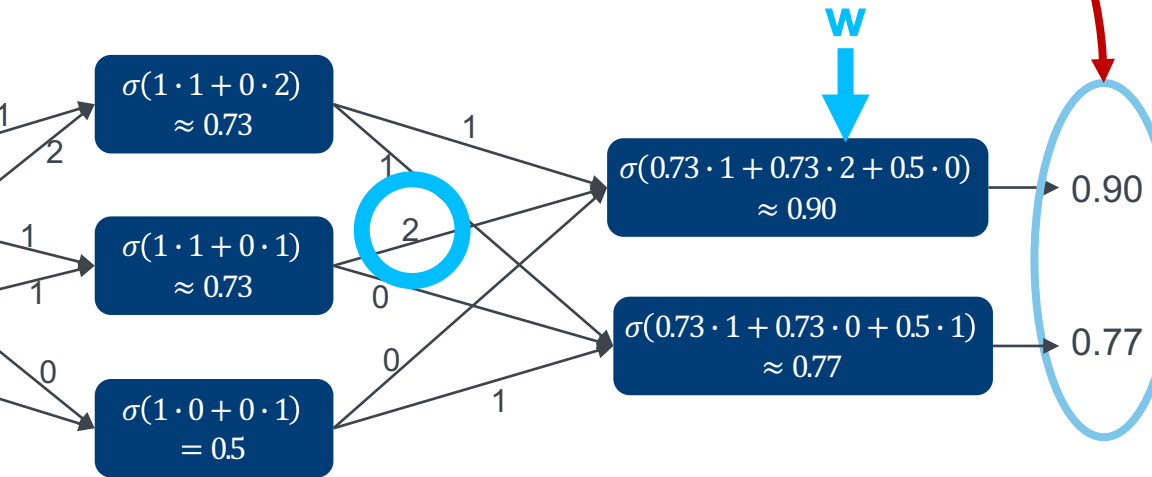
$$C(w_{11}^1, w_{12}^1, \dots, b_1^1, b_2^1, \dots)$$
 - Für jeden Parameter $w_{11}^1, w_{12}^1, \dots, b_1^1, b_2^1, \dots$:
 - Berechne den Gradienten nur für diesen Parameter w



Beispiel-Exkurs: Verlustfunktion für ein Gewicht

- Trainingsdatenpunkt:

Input	Ergebnis
1	5
0	-3



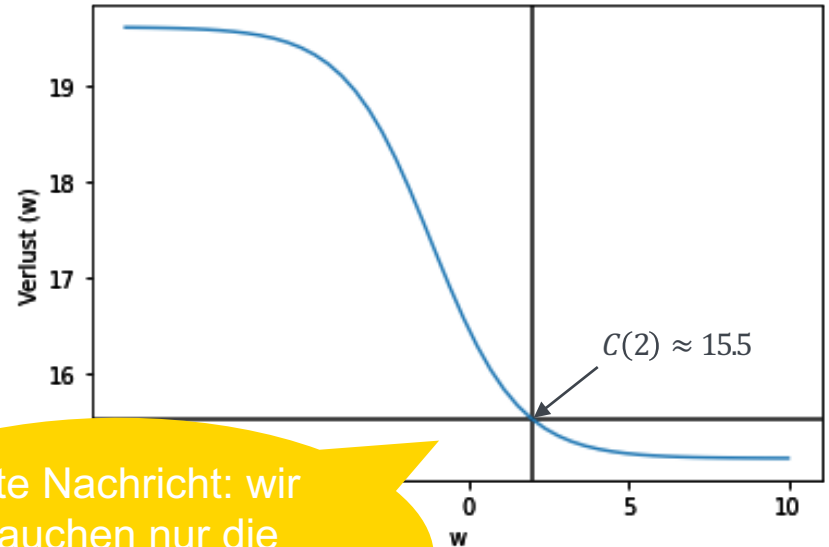
$$\frac{1}{2} \cdot (5 - \sigma(0.73 \cdot 1 + 0.73 \cdot 2 + 0.5 \cdot 0))^2$$

+

$$\frac{1}{2} \cdot (-3 - \sigma(0.73 \cdot 1 + 0.73 \cdot 0 + 0.5 \cdot 1))^2$$

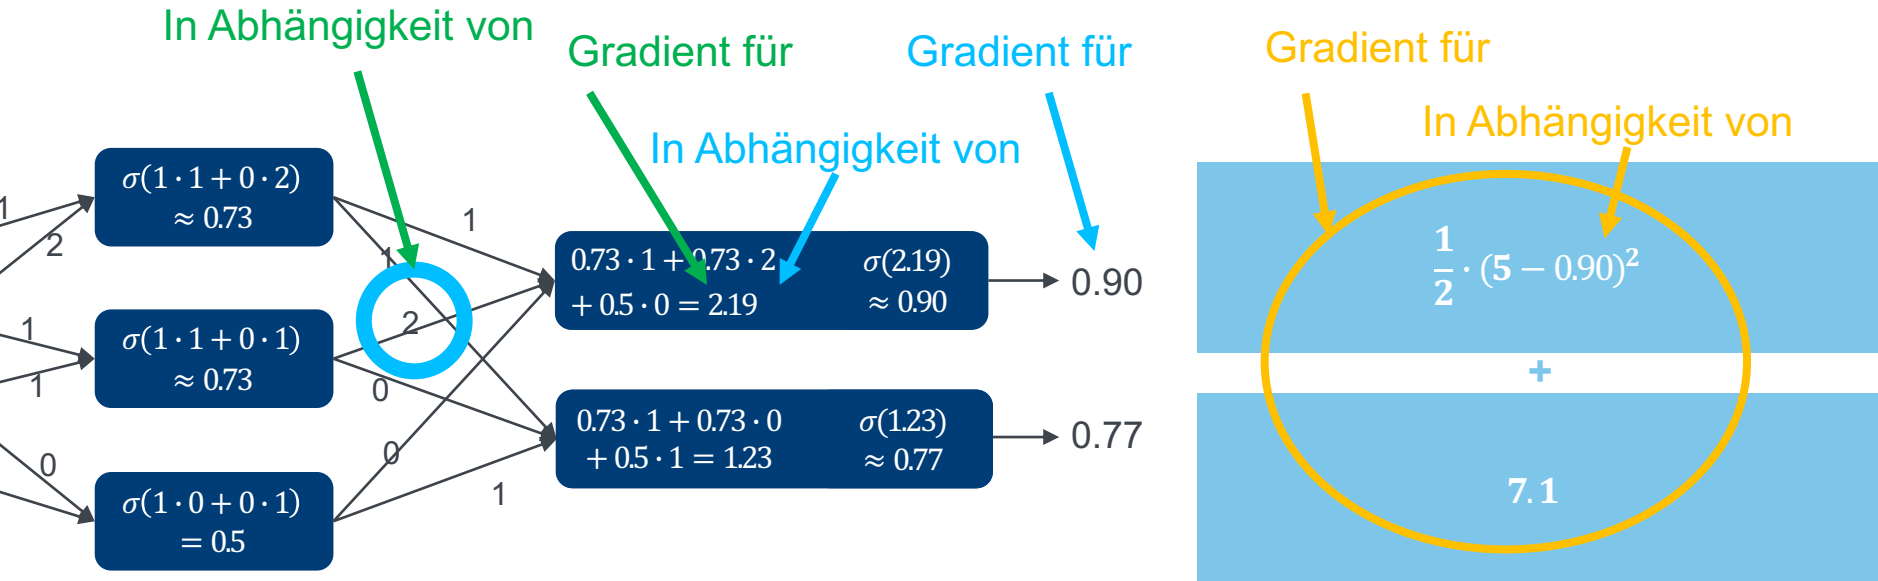
Beispiel-Exkurs: Verlustfunktion für ein Gewicht

- $C(w)$
- Verlust bei $w = 2$:
 - $C(2) \approx 15.5$ ✓
- Verlust wird geringer, wenn w größer wird
(Gradient negativ)



Gute Nachricht: wir brauchen nur die Steigung, d.h. den Gradienten!

Beispiel: Gradienten für ein Gewicht schrittweise berechnen



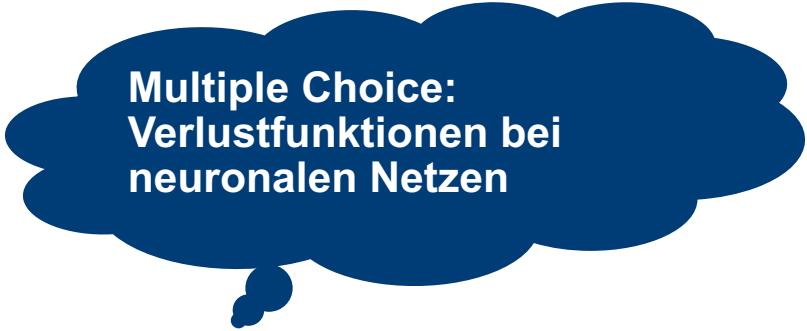
$$(-5 + 0.90) \cdot \sigma(2.19) \cdot (1 - \sigma(2.19)) \cdot 0.73 \approx -0.27$$

Wann berechnet man die Verlustfunktion?

- Beim Training, aber nur indirekt
- Zunächst Berechnung des Verlusts bei den aktuellen Parametern
- Dann Berechnung der **Gradienten** der Verlustfunktion für jeden Parameter
 - Berechnung oft einfacher als die Berechnung der Funktion selbst
 - Wird bei Back Propagation Schritt für Schritt berechnet

Bei Regressionsproblemen in neuronalen Netzen wird meist das mittlere Fehlerquadrat (Mean squared error, MSE) als Verlustfunktion verwendet.

Man berechnet dann also zur Anpassung der Gewichte beim Training für jedes Gewicht den Gradienten der MSE-Funktion.



**Multiple Choice:
Verlustfunktionen bei
neuronalen Netzen**



**Drag the Words: MSE als
Verlustfunktion**



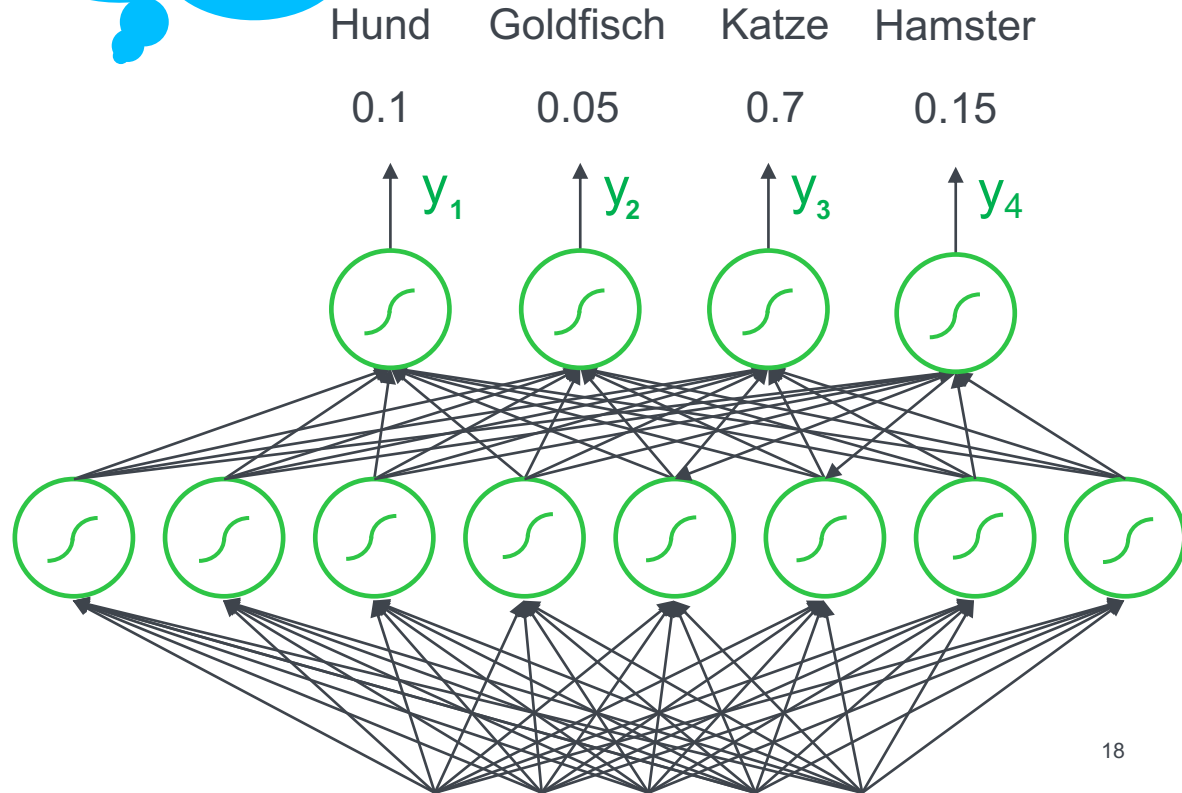
**Multiple Choice: Eigenschaften
des Mean Squared Error**

Verlustfunktion bei Klassifikation

Netzwerk für Klassifikation

Wie vergleicht man
Wahrscheinlichkeits-
verteilungen?

- Mehrere Ausgänge
- Ausgangswerte entsprechen Wahrscheinlichkeiten
- Insgesamt Wahrscheinlichkeit 1 (100%)
- „Wahrscheinlichkeitsverteilung“
- Ziel: möglichst nah an der „wahren“ Wahrscheinlichkeitsverteilung



Rückblick: Entropie beim Bau von Klassifikationsbäumen

- Maß für Unordnung

• Hund 30%	$-\log(0.3)$	* 0.3
• Katze 40%	$-\log(0.4)$	* 0.4
• Hamster 30%	$-\log(0.3)$	* 0.3

Summe: Entropie

Überraschungs-
wert

Klassen-
wahrscheinl.

- „Bewertet“ eine Wahrscheinlichkeitsverteilung

- Niedrig, wenn es sehr wahrscheinliche Ereignisse gibt:

• $-\log(0.999) \cdot 0.999 \approx 0.001 \cdot 0.999 \approx 0.001$	• $-\log(0.998) \cdot 0.998 \approx 0.002 \cdot 0.998 \approx 0.002$
• $-\log(0.001) \cdot 0.001 \approx 6.908 \cdot 0.001 \approx 0.007$	• $-\log(0.002) \cdot 0.002 \approx 6.215 \cdot 0.002 \approx 0.012$

„billiger“

„teurer“

Vergleich zweier Wahrscheinlichkeitsverteilungen

- Von Modell vorhergesagte Wahrscheinlichkeit

- Hund 10%
- Goldfisch 5%
- Katze 70%
- Hamster 15%

Überraschungswert

$$-\log(0.1) \approx 2.30$$

$$-\log(0.05) \approx 3.00$$

$$-\log(0.7) \approx 0.36$$

$$-\log(0.15) \approx 1.90$$

Korrekte Wahrscheinlichkeitsverteilung

$$\cdot 0.2$$

$$\cdot 0.1$$

$$\cdot 0.4$$

$$\cdot 0.3$$

- Hund 20%
- Goldfisch 10%
- Katze 40%
- Hamster 30%

Summe: 1.47

- Teuer, wenn für eine Klasse, die in Wirklichkeit sehr wahrscheinlich ist, ein niedriger Wert vorhergesagt wird

Kreuzentropie

Die Kreuzentropie (engl. Cross Entropy) erhält man, indem man die Überraschungswerte der vorhergesagten Klassenwahrscheinlichkeiten mit den wahren Klassenwahrscheinlichkeiten multipliziert und aufsummiert.

Je niedriger die Kreuzentropie, desto ähnlicher sind sich die vorhergesagte und die wahre Wahrscheinlichkeitsverteilung.

Bei neuronalen Netzwerken für Klassifikationsprobleme wird meist die Kreuzentropie als Verlustfunktion eingesetzt.

Man bezeichnet diese Verlustfunktion dann manchmal auch als „Log Loss“.

Kreuzentropie in der praktischen Anwendung

- In der praktischen Anwendung ist die wahre Verteilung der Klassenwahrscheinlichkeiten nicht bekannt
- Statt dessen Abgleich mit Trainingsdatenpunkt
- Von Modell vorhergesagte Wahrscheinlichkeit
 - Hund 10%
 - Goldfisch 5%
 - Katze 70%
 - Hamster 15%
- Trainingsdatenpunkt:
 - Hund 0%
 - Goldfisch 0%
 - Katze 100%
 - Hamster 0%

Kreuzentropie:
 $-\log(0.7) \cdot 1 \approx 0.36$

Kreuzentropie bei falsch vorhergesagter Klasse

- Von Modell vorhergesagte Wahrscheinlichkeit
 - Hund 10%
 - Goldfisch 5%
 - Katze 70%
 - Hamster 15%

- Trainingsdatenpunkt:

- Hamster

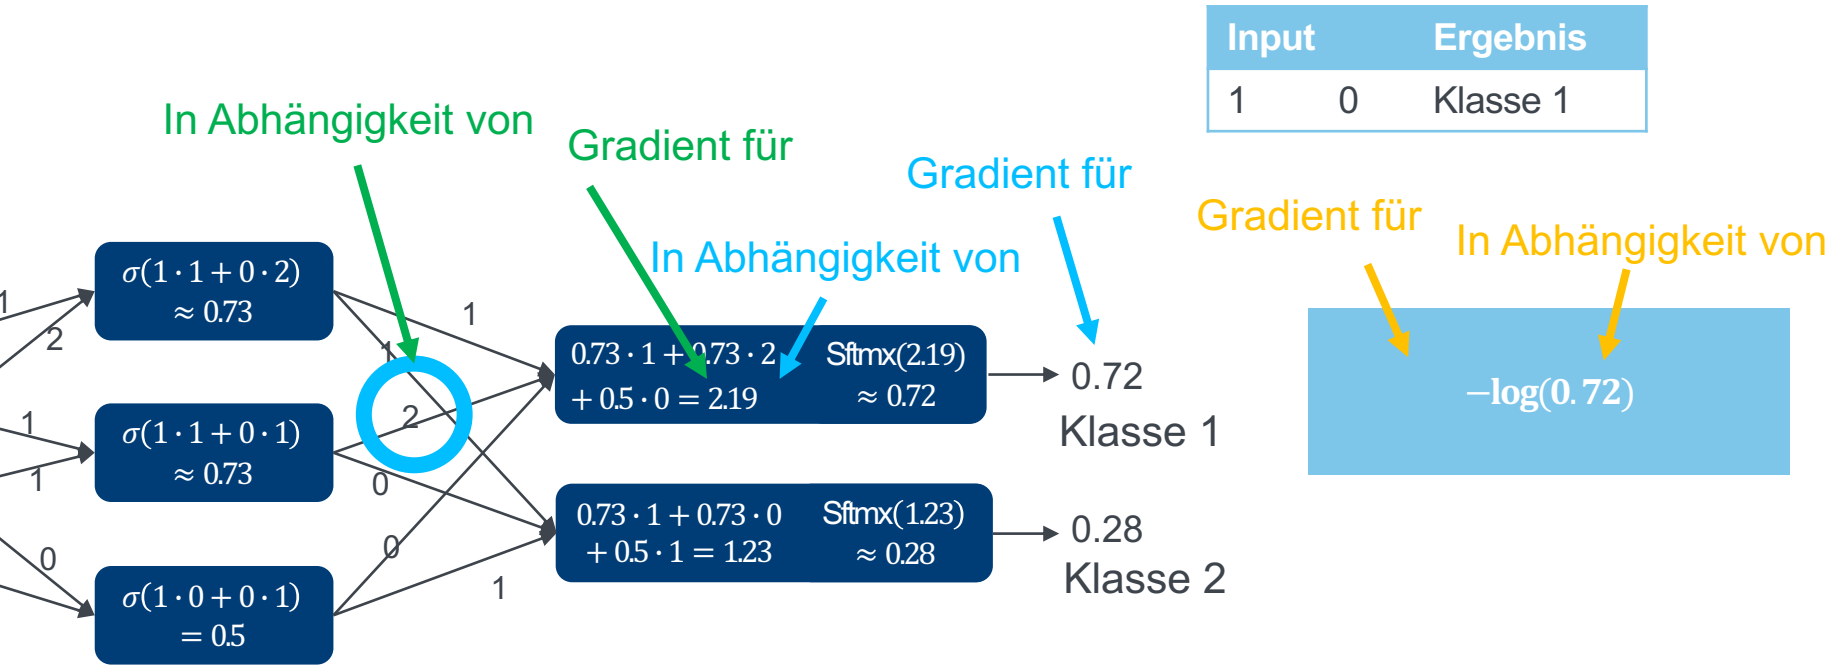
- Hund 0%
- Goldfisch 0%
- Katze 0%
- Hamster 100%

Kreuzentropie:
 $-\log(0.15) \cdot 1 \approx 1.90$

Bei der Berechnung der Kreuzentropie für einzelne Trainingsdatenpunkte nimmt man als wahre Wahrscheinlichkeitsverteilung 100% für die laut Trainingsdatenpunkt korrekte Klasse an, und 0% für alle anderen Klassen.

Dadurch vereinfacht sich die Berechnung der Kreuzentropie auf den Überraschungswert der für die korrekte Klasse vorhergesagten Wahrscheinlichkeit.

Beispiel: Gradienten für ein Gewicht schrittweise berechnen



$$-\frac{1}{0.72} \cdot 2.19 \cdot (1 - 2.19) \cdot 0.73 \approx 2.64$$

Zusammenfassung

- Die Verlustfunktion gibt beim Training das Ziel vor
- Ziel: den Verlust minimieren
- Anpassung der Parameter immer mithilfe der Gradienten der Verlustfunktion
- Verlustfunktionen:
 - Bei Regressionsproblemen: MSE
 - Bei Klassifikationsproblemen: Kreuzentropie
- In beiden Fällen wird einmal der Gesamtverlust berechnet (Forward Pass)
- Anschließend bei der Back Propagation Schritt für Schritt die Gradienten der Verlustfunktion für alle Parameter



**Question Set: Entropie und
Kreuzentropie**



**Multiple Choice: Gradienten
der Verlustfunktion**

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



Lizenzbestimmungen

“Verlustfunktion” 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 \(https://creativecommons.org/licenses/by/4.0/deed.de\)](https://creativecommons.org/licenses/by/4.0/deed.de)

(Namensnennung 4.0 International)

Quellenverzeichnis

Titelfoto: [Markus Winkler \(https://unsplash.com/de/@markuswinkler\)](https://unsplash.com/de/@markuswinkler), ohne Titel, auf [Unsplash \(https://unsplash.com/de/fotos/afW1hht0NSs\)](https://unsplash.com/de/fotos/afW1hht0NSs), ist lizenziert unter [Unsplash-Lizenz \(https://unsplash.com/license\)](https://unsplash.com/license).

Bildausschnitt verändert.