



Anwendungen der KI
– Sommersemester 2018 –

Kapitel 05: Machine Learning

Prof. Dr. Adrian Ulges
B.Sc. Informatik (AI, ITS, MI, WI)
Fachbereich DCSM
Hochschule RheinMain


Machine Learning: Fragestellungen



Regression



Clustering / Segmentierung



Recommendation

amazon.com Recommended for You

Amazon.com has new recommendations for you based on [items](#) you purchased or told us you own.

 The Little Red Riding Hood WAVE TO DANCE EXCELLENCE	 Enchanted, Your 7 Choices to Personalize and Celebrate	 Sherlock Holmes: The Hound of the Baskervilles	 Alice in Wonderland [Illustrated]
--	--	---	---

Klassifikation



Datenreduktion



Ausreißererkennung





*“Machine learning is the [...] study of **algorithms that can learn from data**. Such algorithms operate by building a **model** from **example inputs** and using that to make **predictions or decisions**.”*

(en.wikipedia.org)

*“The field of study that gives computers the ability to learn **without being explicitly programmed**.”*

(Arthur Samuel (1959))

*“A computer program is said to **learn** from experience E with respect to some task T and some performance measure P , if its performance on T , as measured by P , improves with Experience E .”*

(Tom Mitchell (1998))



Wir verwenden Machine Learning, um aus **Beispieldaten** zu lernen, wie ein Wort/Satz/Dokument im Rahmen des gegebenen Kontexts zu **interpretieren** ist.

Beispiele

1. Part-of-Speech (POS) Tagging: Bestimmung der Wortart¹

"The **bear** survives in summer on fish and fruit." → NN

"Your efforts will **bear** fruit." → VB

(im Schnitt ca. 2 mögliche Wortarten pro Term, 92% Genauigkeit durch Wahl der häufigsten Wortart, 97% durch Machine Learning.)

2. Sentiment-Analyse

"I can not believe it – What a cool video!" → 😊

"This video is not cool – What a..." → 😞

3. Antworttyp-Detektion

"Who founded Virgin Airlines" → PERSON/INDIVIDUAL

"What state capital is the largest?" → GEO/CITY

¹Englisch: 45 Wortarten im sog. Penn Treebank Tagset



1. Grundlagen
2. Logistische Regression
3. Grundlagen II
4. Anwendung im NLP I: Sentiment-Klassifikation
5. Named Entity Recognition



Stichprobe (engl. "Samples")

- ▶ Das Ziel von Data Mining sind Aussagen / Prognosen über Objekte der Welt
 - ▶ **News-Classifer**: Objekte = News-Artikel
 - ▶ **Routenplaner**: Objekte = zu planende Fahrten
- ▶ Zum Lernen sammeln wir eine Stichprobe von Objekten und bezeichnen diese als **Samples**.

Merkmale (engl. "features")

- ▶ Wir beschreiben jedes Sample anhand von **Merkmalen**
 - ▶ **News-Classifer**: Merkmale = Autor, Schlüsselwörter, ...
 - ▶ **Routenplaner**: Merkmale = Tageszeit, Start, Ziel, ...
- ▶ Wir fassen alle Merkmale in einem **Merkmalsvektor** x zusammen



Merkmale (cont'd)

- ▶ Merkmale können **qualitativ** (Bsp. *Farbe*) oder **quantitativ** (Bsp. *Alter*) sein.
- ▶ Wir können qualitative Merkmale mit **Indikator-Variablen** (engl. **One-Hot Encoding**) in quantitative überführen.

	PS	Farbe	PS	ist_grün	ist_silber	ist_rot
Auto von Prof. Ulges	70	weiß	73	0	0	0
Auto von Prof. Ulges' Frau	690	rot	690	0	0	1

- ! Wir können Samples (meist) als **Punkte** in einem (*hochdimensionalen*) Raum interpretieren!
- ▶ Häufig: **Vorverarbeitung** der Daten
 - ▶ Schätzung fehlender Werte (engl. “**imputation**”)
 - ▶ Verwerfen von Ausreißern
 - ▶ Vorauswahl der “wichtigen” Merkmale
 - ▶ **Standardisierung** der einzelnen Merkmale



Überwachtes Lernen

- ▶ Unser Ziel ist eine **Prognose** über ein Objekt. Wir bezeichnen den vorhergesagten Wert als **Label** oder **Target**.
- ▶ Lerne von Samples $\mathbf{x}_1, \dots, \mathbf{x}_n$ und Labels y_1, \dots, y_n
- ▶ Labels können **reellwertig** sein (\rightarrow **Regressions-Problem**)
 - ▶ **Bsp: Routenplaner:** $y_i \in \mathbb{R}_0^+$ (= *Zeit bis zum Ziel*)
- ▶ Labels können **nominal** sein, d.h. die Zugehörigkeit zu **Kategorien** ausdrücken (\rightarrow **Klassifikations-Problem**).
 - ▶ **Bsp: Suchmaschine:** $y_i \in \{\text{relevant}, \text{irrelevant}\}$ (bzw. $\{0, 1\}$)


Unüberwachtes Lernen

- ▶ Unüberwachtes Lernen = Lernen **ohne Labels**
- ▶ Lerne von Samples $\mathbf{x}_1, \dots, \mathbf{x}_n$
- ▶ **Aufgabe:** Lerne die **Struktur** der Daten:
Untergruppen, häufige Muster, Ausreißer/Anomalien

Überwachtes Lernen: (Batch-)Pipeline²



1. Wir **trainieren** das System in einer Offline-Phase und erhalten ein **Modell**
2. Wir wenden das Modell in der **Online-Phase** an



²Bildquelle: <http://www.99designs.com>

Machine Learning: Eingabedaten




	A	B	C	D	E	F	G	H	I	J	K	L
1	PassengerId	Survived	class	Name	Sex	Age	SibSp	Parch	Ticket	Fare	Cabin	Embarked
2	0	0	3	Braund, Mr. Owen Harris	male	22	1	0	A/5 21171	7.25		S
3	0	1	1	Cummings, Mrs. John Bradley (Florence Briggs Thayer)	female	38	1	0	PC 17599	71.2833	C85	C
4	0	1	3	Heikkinen, Miss. Laina	female	26	0	0	STON/O2 3101282	79.25		S
5	0	1	1	Futrelle, Mrs. Jacques Heath (Lily May Peel)	female	35	1	0		113803.53	C123	S
6	0	0	3	Allen, Mr. William Henry	male	35	0	0		373450.85		S
7	0	0	3	Moran, Mr. James	male	0	0	0		330877.84583		Q
8	0	0	1	McCarthy, Mr. Timothy J	male	54	0	0		17463.518625	E46	S
9	0	0	3	Palsson, Master. Gosta Leonard	male	2	3	1		349509	21075	S
10	0	1	3	Johnson, Mrs. Oscar W (Elisabeth Vilhelmina Berg)	female	27	0	2		347742.111333		S
11	0	1	2	Nasser, Mrs. Nicholas (Adele Achem)	female	14	1	0		237736.300708		C
12	0	1	3	Sandstrom, Miss. Marguerite Rut	female	4	1	1	PP 9549	16.7	G6	S
13	0	1	1	Bonnell, Miss. Elizabeth	female	58	0	0		113783.2655	C103	S
14	0	0	3	Saunderscock, Mr. William Henry	male	20	0	0	A/5. 2151	8.05		S
15	0	0	3	Andersson, Mr. Anders Johan	male	39	1	5		347082	31275	S
16	0	0	3	Vestrom, Miss. Hulda Amanda Adolfina	female	14	0	0		350406.78542		S
17	0	1	2	Hewlett, Mrs. (Mary D Kingcome)	female	55	0	0		248706	16	S
18	0	0	3	Rice, Master. Eugene	male	2	4	1		382652	29125	O
19	0	1	2	Williams, Mr. Charles Eugene								
20	0	0	3	Vander Planke, Mrs. Julius (Emelia Maria Van)								
21	0	2	1	Masselmanni, Mrs. Fatima								
22	0	2	0	Fynney, Mr. Joseph J								
23	0	2	1	Beesley, Mr. Lawrence								
24	0	2	1	McGowan, Miss. Anna "Annie"								
25	0	2	1	Sloper, Mr. William Thompson								
26	0	2	0	Palsson, Miss. Torborg Danira								
27	0	2	1	Asplund, Mrs. Carl Oscar (Selma Augusta Em								
28	0	2	0	Emir, Mr. Farred Chehab								
29	0	2	0	Fortune, Mr. Charles Alexander								
30	0	2	1	O'Dwyer, Miss. Ellen "Nellie"								
31	0	3	0	Todoroff, Mr. Lailo								
32	0	3	0	Uruchuru, Don. Manuel E								
33	0	3	1	Spencer, Mrs. William Augustus (Marie Eugeni								
34	0	3	1	Glynn, Miss. Mary Agatha								
35	0	3	0	Whaddon, Mr. Edward H								
36	0	3	0	Meyer, Mr. Edgar Joseph								
37	0	3	0	Holverson, Mr. Alexander Oskar								
38	0	3	1	Mamee, Mr. Hanna								
39	0	3	0	Cann, Mr. Ernest Charles								
40	0	3	0	Vander Planke, Miss. Augusta Maria								
41	0	4	1	Nicola-Yared, Miss. Jamila								
42	0	4	0	Ahlin, Mrs. Johan (Johanna Persdotter Larsson								
43	0	4	0	Turpin, Mrs. William John Robert (Dorothy Ann								
44	0	4	0	Kraeff, Mr. Theodor								



Machine Learning: Eingabedaten (geometrisch)



- ▶ **Szenario:** Klassifikation (ordne Sample \mathbf{x} einer Klasse c zu)
- ▶ **Ziel:** Berechne $P(c|\mathbf{x})$ für jede Klasse c .
- ▶ Hieraus ergeben sich **Entscheidungsregionen** und -**Grenzen**.





1. Grundlagen
2. Logistische Regression
3. Grundlagen II
4. Anwendung im NLP I: Sentiment-Klassifikation
5. Named Entity Recognition



- ▶ **Logistische Regression** ist ein einfaches, weit verbreitetes Modell zur Klassifikation.
- ▶ Gegeben: Trainingssamples $\mathbf{x}_1, \dots, \mathbf{x}_n \in \mathbb{R}^d$ mit zugehörigen Labels y_1, \dots, y_n (Klassen-Zugehörigkeit).
- ▶ Ziel: Lerne eine **Klassifikator**-Funktion $\mathbb{R}^d \rightarrow \{0, 1\}$, die den Samples eine **Klasse C** zuordnet
(erstmal nur 2 mögliche Klassen: Erfolg/Misserfolg, gesund/krank, Spam/Ham!).

Der Ansatz...


- ▶ ... ist **probabilistisch**: Unser Modell schätzt $P(C = 1|\mathbf{x})$.
- ▶ Der Klassifikator entscheidet sich für die Klasse mit **maximaler Wahrscheinlichkeit**.

Logistische Regression: Ansatz



Beispiel: Mathe-Klausur

- ▶ x = Lernaufwand, C = bestanden / nicht bestanden
- ▶ **Gegeben:** Eine Trainingsmenge $x_1, x_2, \dots, x_n \in \mathbb{R}$ mit Labels $y_1, y_2, \dots, y_n \in \{0, 1\}$.
- ▶ **Ziel:** Ermittle $P(C = 1|x)$ für ein Test-Sample x




Logistische Regression: Grundmodell



- ▶ Wir verwenden für die Regressionsfunktion als **Grundmodell** die sogenannte **Sigmoid-Funktion**

$$P(C = 1|x) := f(x) = \frac{1}{1 + e^{-x}}$$



- ▶ Es gilt: $\lim_{x \rightarrow -\infty} f(x) = 0$ und $\lim_{x \rightarrow \infty} f(x) = 1$
- ▶ Es gilt: $P(C = 1|x = 0) = f(0) = 0.5$.

Wir entscheiden uns also für Klasse 1, falls $x \geq 0$.

Logistische Regression: Grundmodell






Erweiterung

- ▶ Wir erlauben eine **Verschiebung** und **Streckung/Stauchung/Spiegelung** der Funktion!
- ▶ Wir erhalten als Modell:

$$f(x; w_0, w) = \frac{1}{1 + e^{-(w_0 + w \cdot x)}}$$

- ▶ Die Parameter w_0, w werden beim **Training** ermittelt (*gleich*).





Warum dieses Modell?

- ▶ **Einfachheit**, Intuition.
- ▶ Das Modell ist korrekt für **normalverteilte** Klassen gleicher Varianz.
- ▶ **Tradition**.
- ▶ **Wenige Parameter** zu fitten → Gute Ergebnisse bereits bei wenigen Trainingsamples.

Würde **lineare** Regression funktionieren? → Nein, denn ...

- ▶ ... wir können durch die Daten keine sinnvolle Gerade fitten
- ▶ ... die prognostizierten Wahrscheinlichkeiten lägen nicht zwischen 0 und 1

Logistische Regression im Mehrdimensionalen



- ▶ Wie modellieren wir **multivariate** Samples $\mathbf{x} \in \mathbb{R}^d$?
- ▶ Wir erweitern die Sigmoid-Funktion:



$$f(\mathbf{x}; w_0, w_1, w_2, \dots, w_d) = \frac{1}{1 + e^{-(w_0 + w_1 \cdot x_1 + w_2 \cdot x_2 + \dots + w_d \cdot x_d)}}$$

oder kurz (mit Vektor $\mathbf{w} := (w_1, \dots, w_d)$):

$$f(\mathbf{x}; w_0, \mathbf{w}) = \frac{1}{1 + e^{-(w_0 + \mathbf{x} \cdot \mathbf{w})}}$$

- ▶ Die Entscheidungsgrenze dieses Modells liegt bei $\mathbf{x} \cdot \mathbf{w} + w_0 = 0$. Dies entspricht einer **Hyperebene** (in Normalenform)!

Logistische Regression: Illustration



- ▶ Die Entscheidungsgrenze ist linear. Wir sprechen bei logistischer Regression deshalb auch von einem **linearen Klassifikator** (*es gibt noch einige weitere!*).
- ▶ Der Parameter \mathbf{w} bestimmt die Orientierung der Entscheidungsgrenze, w_0 verschiebt die Grenze.
- ▶ \mathbf{w} bestimmt darüber hinaus die **Glätte** der Entscheidungsfunktion f .



Schlüsselfrage: Training

- ▶ Gegeben ist eine Trainingsmenge von Samples $\mathbf{x}_1, \dots, \mathbf{x}_n \in \mathbb{R}^d$ mit Labels $y_1, \dots, y_n \in \{0, 1\}$
- ▶ **Ziel:** Bestimme w_0 und \mathbf{w} , also die Position der Entscheidungsgrenze und Glätte der Entscheidungsfunktion

Ansatz: Maximum-likelihood-Schätzung



- ▶ **Grundidee:** Wähle die Parameter so, dass die beobachteten Daten “maximal wahrscheinlich” werden
- ▶ Für **positive** Samples ($y_i = 1$) sollte $f(\mathbf{x}_i)$ möglichst **groß** sein:

$$\left(P(C = 1 | \mathbf{x}_i) \right) \approx f(\mathbf{x}_i) \approx 1$$

- ▶ Für **negative** Samples ($y_i = 0$) sollte $f(\mathbf{x}_i)$ möglichst **klein** sein:

$$\left(P(C = 1 | \mathbf{x}_i) \right) \approx f(\mathbf{x}_i) \approx 0$$

Logistische Regression: Beispiel



Maximum-Likelihood-Schätzung

Wir formulieren eine sogenannte Likelihood-Funktion und stellen ein Maximierungsproblem auf:

$$w_0^*, \mathbf{w}^* = \arg \max_{w_0, \mathbf{w}} \underbrace{\prod_{i:y_i=1} f(\mathbf{x}_i) \cdot \prod_{i:y_i=0} (1 - f(\mathbf{x}_i))}_{\text{"Likelihood-Funktion" } L(w_0, \mathbf{w})}$$

Wir formen das Maximierungsproblem um:

$$\begin{aligned} w_0^*, \mathbf{w}^* &= \arg \max_{w_0, \mathbf{w}} \prod_{i:y_i=1} f(\mathbf{x}_i) \cdot \prod_{i:y_i=0} (1 - f(\mathbf{x}_i)) \\ &= \arg \max_{w_0, \mathbf{w}} \prod_i f(\mathbf{x}_i)^{y_i} \cdot (1 - f(\mathbf{x}_i))^{1-y_i} \quad // \log \\ &= \arg \max_{w_0, \mathbf{w}} \sum_i y_i \cdot \log(f(\mathbf{x}_i)) + (1 - y_i) \cdot \log(1 - f(\mathbf{x}_i)) \end{aligned}$$

Logistische Regression: Ansatz




$$\begin{aligned}w_0^*, \mathbf{w}^* &= \arg \max_{w_0, \mathbf{w}} \underbrace{\prod_{i:y_i=1} f(\mathbf{x}_i) \cdot \prod_{i:y_i=0} (1 - f(\mathbf{x}_i))}_{\text{"Likelihood-Funktion" } L(w_0, \mathbf{w})} \\&= \arg \max_{w_0, \mathbf{w}} \prod_i f(\mathbf{x}_i)^{y_i} \cdot (1 - f(\mathbf{x}_i))^{1-y_i} \quad // \log \\&= \arg \max_{w_0, \mathbf{w}} \sum_i y_i \cdot \log(f(\mathbf{x}_i)) + (1 - y_i) \cdot \log(1 - f(\mathbf{x}_i)) \\&= \arg \max_{w_0, \mathbf{w}} \sum_i \log(1 - f(\mathbf{x}_i)) + y_i \cdot \log\left(\frac{f(\mathbf{x}_i)}{1 - f(\mathbf{x}_i)}\right) \\&= \arg \max_{w_0, \mathbf{w}} \sum_i \log\left(\frac{1 + \exp(-(w_0 + \mathbf{x}_i \mathbf{w})) - 1}{1 + \exp(-(w_0 + \mathbf{x}_i \mathbf{w}))}\right) + y_i \cdot \log\left(\frac{1}{\frac{(1 + \exp(-(w_0 + \mathbf{x}_i \mathbf{w}))}{\exp(-(w_0 + \mathbf{x}_i \mathbf{w}))})}{(1 + \exp(-(w_0 + \mathbf{x}_i \mathbf{w}))}}}\right) \\&= \arg \max_{w_0, \mathbf{w}} \sum_i -\log\left(\frac{1 + \exp(-(w_0 + \mathbf{x}_i \mathbf{w}))}{\exp(-(w_0 + \mathbf{x}_i \mathbf{w}))}\right) - y_i \cdot \log(\exp(-(w_0 + \mathbf{x}_i \mathbf{w}))) \\&= \arg \max_{w_0, \mathbf{w}} \sum_i -\log(e^{w_0 + \mathbf{x}_i \mathbf{w}} + 1) + \sum_i y_i \cdot (w_0 + \mathbf{x}_i \mathbf{w})\end{aligned}$$

$$\arg \max_{w_0, \mathbf{w}} \underbrace{\sum_i -\log(e^{w_0 + \mathbf{x}_i \mathbf{w}} + 1) + \sum_i y_i \cdot (w_0 + \mathbf{x}_i \mathbf{w})}_{\text{"Log-Likelihood-Funktion" } l(w_0, \mathbf{w})}$$

Anmerkungen

- ▶ Diese Log-Likelihood-Funktion ist nicht analytisch minimierbar. Es gibt aber **numerische Lösungen**: Finde z.B. Nullstellen der Ableitung mit Hilfe des **Newton-Verfahrens**.
- ▶ Die Gewichte in \mathbf{w} zeigen die **Bedeutung** der einzelnen Merkmale für das Klassifikationsproblem an.

Logistische Regression: Code-Beispiel



- ▶ Bag-of-Words Features
- ▶ Logistische Regression
- ▶ Inspektion der Merkmals-Gewichte



- ▶ **Beobachtung:** Das gelernte Modell tendiert zum **Overfitting**, wenn ...
 - ▶ ... einzelne Merkmale zu hohe Gewichte erhalten
 - ▶ ... viele unwichtige Merkmale ein Gewicht $\neq 0$ erhalten
- ▶ Deshalb **regularisieren** wir das Problem, so dass die Einträge in \mathbf{w} eher klein (bzw. null) sind.
- ▶ Wir definieren eine **Norm** des Gewichtsvektors \mathbf{w}

$$\|\mathbf{w}\|_1 := |w_1| + |w_2| + \dots + |w_d| \quad \text{L1-Norm}$$

$$\|\mathbf{w}\|_2 := \sqrt{w_1^2 + w_2^2 + \dots + w_d^2} \quad \text{L2-Norm}$$

- ▶ Wir passen das Optimierungsproblem an, so dass hohe Gewichte in \mathbf{w} "bestraft" werden:


$$\arg \max_{w_0, \mathbf{w}} l(w_0, \mathbf{w}) - C \cdot \|\mathbf{w}\|_1 \quad // \text{ L1-Regularisierung}$$

$$\arg \max_{w_0, \mathbf{w}} l(w_0, \mathbf{w}) - C \cdot \|\mathbf{w}\|_2 \quad // \text{ L2-Regularisierung}$$

Logistische Regression: Regularisierung



Welchen Unterschied macht der Typ der Regularisierung?



- ▶ Im Bild: $\mathbf{w} = (0, 1)$ (= L1-Lösung)
vs. $\mathbf{w} = (0.15, 0.99)$ (=L2-Lösung)
- ▶ L1-Regularisierung setzt die Gewichte uninformativer Features auf 0 (engl. “sparsity”). Das heißt, der Klassifikator führt eine interne **Merkmalsselektion** durch!
- ▶ L2-Regularisierung reduziert Ausreißer (= *extreme Gewichte*).

Logistische Regression: Fazit



- ▶ Logistische Regression ist ein sehr **einfaches** Modell
- ▶ Nur lineare Entscheidungsgrenzen sind modellierbar!
- ▶ **Grundprinzip**: Weise jedem Merkmal ein **Gewicht** zu.
- ▶ Klappt schon mit relativ **wenigen Trainingsamples** gut.
Faustregel: ca. 10 Trainingsamples pro Klasse pro Merkmal.



1. Grundlagen
2. Logistische Regression
- 3. Grundlagen II**
4. Anwendung im NLP I: Sentiment-Klassifikation
5. Named Entity Recognition

Klassifikation: Illustration im Merkmalsraum






“The real value of a scientific explanation lies not in its ability to explain (what one has already seen), but in predicting events that have yet to (be seen).”

(Blumer et al. 1987)

-
- ▶ Die Fähigkeit der eines Klassifikators, von den Trainingsdaten auf (neue) Testdaten zu schließen, bezeichnen wir als **Generalisierung**.
 - ▶ Funktioniert ein Klassifikator sehr gut auf den Trainingsdaten, aber schlecht auf neuen Daten, sprechen wir von **Overfitting**.
 - ▶ Overfitting tritt auf, wenn...
 - ▶ ... die Trainingsmenge sehr klein ist
 - ▶ ... das Modell sehr viele Parameter hat
 - ▶ ... das Modell nicht gut auf die Daten passt



Was wir über maschinelles Lernen wissen

- ▶ Es gibt **zahlreiche** Methoden / Modelle.
- ▶ Es gibt kein **universell bestes** Modell (*no-free-lunch theorem*).


Evaluation von ML-Systemen




- ▶ **Machine Learning** in der Praxis = iterative Auswahl von...
 - ▶ Daten
 - ▶ Merkmalen
 - ▶ Modellen
 - ▶ Parametern
- ▶ **Schlüsseltreiber: Benchmarking**




Data Mining: Benchmarking



- ▶ Wir unterteilen die Daten in **Trainings- und Testdaten**.
- ▶ Wir **benchmarken** (nur) auf den Testdaten.
- ▶ **Todsünde**: “Testing on the Training Data”!
- ▶ **Todsünde (auch)**: “Training on the Test Data”!



- ▶ Einige Parameter des Klassifikators werden **gelernt**, andere (**freie**) Parameter werden **manuell** gesetzt.
- ▶ Typischer Ansatz: **Manuelle Suche** / **Grid Search**.
- ▶ **Beispiel** Logistische Regression: Stärke der Regularisierung C .
- ▶ **Ansatz**: Training → Validieren → Testen.



- ▶ Sind die **Trainingsdaten klein**, teilt man sie in Teile (engl. "**Folds**") und trainiert/validiert **mehrfach**.
- ▶ Die Ergebnisse werden über die Folds gemittelt.



1. Grundlagen
2. Logistische Regression
3. Grundlagen II
4. Anwendung im NLP I: Sentiment-Klassifikation
5. Named Entity Recognition

Wir nehmen zwei Änderungen an logistischer Regression vor:

1. Merkmalsfunktionen

- ▶ Wir verwenden statt Merkmalsvektoren Merkmalsfunktionen f_1, \dots, f_n . Diese nehmen unsere Merkmalsextraktion vor.
- ▶ Eine **Merkmalsfunktion** f_i berechnet – gegeben Eingabewort/Eingabetext x und Klasse c – einen Merkmalswert $f_i(x, c)$.
- ▶ Häufig sind die Merkmalswerte binär (*sogenannte **Indikatorfunktionen***).

Beispiele

- ▶ Sentiment-Klassifikation
- ▶ Satzzeichen-Erkennen: Liegt Satzende (EOS) vor?

$$f_i(x, c) = \begin{cases} 1 & \text{falls ("great" } \in x \\ & \wedge c = +) \\ 0 & \text{sonst} \end{cases}$$

$$f_i(x, c) = \begin{cases} 1 & \text{falls (case}(w_{i+1}) = \textit{upper} \\ & \wedge c = \textit{EOS}) \\ 0 & \text{sonst} \end{cases}$$



2. Behandlung von mehr als zwei Klassen

- ▶ Wir ändern die Formel zur logistischen Regression leicht ab und erhalten die **multinomielle** logistische Regression

$$P(c|x) = \frac{\exp\left(\sum_i w_i \cdot f_i(x, c)\right)}{\sum_{c'} \exp\left(\sum_i w_i \cdot f_i(x, c')\right)}$$

- ▶ **Idee:** Nicht mehr ein exp-Term, der zwischen zwei Klassen entscheidet, sondern ein exp-Term für **jede Klasse!**

Logistische Regression im NLP: Beispiel [1] (Kapitel 7) *

Merkmalsfunktionen

$$f_1(x, c) = \mathbf{1} \text{ 'great'}_{\text{EX}} \wedge c=+$$


$$f_2(x, c) = \mathbf{1} \text{ 'no'}_{\text{EX}} \wedge c=-$$

$$f_3(x, c) = \mathbf{1} \text{ 'second-rate'}_{\text{EX}} \wedge c=-$$

$$f_4(x, c) = \mathbf{1} \text{ 'enjoy'}_{\text{EX}} \wedge c=-$$

$$f_5(x, c) = \mathbf{1} \text{ 'chuck norris'}_{\text{EX}} \wedge c=+$$

Gelernte Gewichte



Klassifikationsergebnis

$$P(c = +|x) = \frac{e^{1.9+0}}{e^{1.9+0} + e^{0.9+0.7-0.8}} = 82\%$$

$$P(c = -|x) = \frac{e^{0.9+0.7-0.8}}{e^{1.9+0} + e^{0.9+0.7-0.8}} = 18\%$$



Gute **Merkmalsfunktionen** hängen vom Klassifikationsproblem ab

- ▶ **Satzzeichen-Erkennung**: Groß/Kleinschreibung, Vorhandensein einer bekannten Abkürzungen (*U.S.A., St., ...*)
- ▶ **Spam-Klassifikation**: Identität des Absenders
- ▶ **Sentiment-Klassifikation**: Adektive, Bigramme (*“very funny” vs. “not funny”*)
- ▶ ...

Häufig treffen wir eine **Vorauswahl**

- ▶ Warum? Effizienzgründe, Overfitting
- ▶ Berechne für jedes Merkmal ein **Proxy-Maß**, das angibt ob eine Korrelation zur Klasse besteht (z.B. *information gain*)
- ▶ Ranke die Merkmale nach diesem Maß und verwende nur die **“besten” K Merkmalsfunktionen** (K : Tausende, ermittelt via Cross-Validation)



1. Grundlagen
2. Logistische Regression
3. Grundlagen II
4. Anwendung im NLP I: Sentiment-Klassifikation
5. Named Entity Recognition



- ▶ **Information Extraction** befasst sich mit der Extraktion von Semantik aus Texten.
- ▶ Im Allgemeinen ist dies nur sehr eingeschränkt möglich: Extraktion einfacher **Fakten**

Hier: Named Entities

- ▶ Eine “named entity” ist ein **eindeutiges, benanntes Objekt**.

Named Entities

Donald J. Trump, McDonalds, Nile,
13.04.2017, 20\$

Keine Named Entities

sand, cat, company

- ▶ Oft werden (*siehe Beispiele*) Datums- oder Zahlenangaben dazugezählt.
- ▶ In der Regel werden Entitäten auch **Klassen** zugeordnet (z.B. “person”, “organization”, “money”, “location”)

Named Entity Recognition (NER): Beispiel Bild: [1]



Citing high fuel prices, [ORG **United Airlines**] said [TIME **Friday**] it has increased fares by [MONEY **\$6**] per round trip on flights to some cities also served by lower-cost carriers. [ORG **American Airlines**], a unit of [ORG **AMR Corp.**], immediately matched the move, spokesman [PER **Tim Wagner**] said. [ORG **United**], a unit of [ORG **UAL Corp.**], said the increase took effect [TIME **Thursday**] and applies to most routes where it competes against discount carriers, such as [LOC **Chicago**] to [LOC **Dallas**] and [LOC **Denver**] to [LOC **San Francisco**].

Anwendungen

- ▶ **Verknüpfung** von Texten mit strukturierten Quellen
(z.B. *Wikipedia*)
- ▶ **Sentiment-Analyse**: *Über wen* wird gesprochen?
- ▶ **Question Answering**: Detektion von *Anwort-Kandidaten*



1. **Klassifikation:** Gegeben einen Satz, weise jedem Term ein Label (z.B. *PERSON*, *ORGA*, *LOCATION*, *TIME*,...) zu.
Sonderfall: O ("Other", gehört zu keiner Named Entity).

"*[PERSON Washington] [O was] [O born] [O into] [O slavery]*" vs.
"*[O Blair] [O arrived] [O in] [LOC Washington] [O to] [O visit]*."

2. **Segmentierung:** Wo sind die Grenzen zwischen Named Entities?

Als *Angela Merkel* *Seehofer* rügte...

3. Clustering von Entitäten


Trump = the president = Agent Orange

NER: Problemstellung



Ansätze: Häufig eine Kombination aus...

- ▶ Regel-Systemen



- ▶ Matching von n-Grammen gegen Verzeichnisse **bekannter** Namen/Orte/Personen
- ▶ Machine Learning (*hier*)

- ▶ Wir formulieren NER als sogenanntes **Sequence Labeling**: Gegeben eine Sequenz von Buchstaben x_1, \dots, x_n , bestimme eine zugehörige Sequenz von Tags t_1, \dots, t_n .
- ▶ Wir bestimmen den **Tag-Vokabular** geschickt so, dass die Labels sowohl den **Typ** als auch die **Grenzen** der Named Entities bestimmen!

3 Arten Labels ("BIO"-Labels)

1. **B-T**: Eine Named Entity mit Typ T **beginnt** hier (*B-PERSON, B-LOCATION, ...*)
2. **I-T**: Das Token gehört zu einer Named Entity mit Typ T, aber diese **beginnt hier nicht** (*I-PERSON, I-LOCATION, ...*)
3. **O**: Das Token gehört zu **keiner** Named Entity.

America	Airlines	,	a	company	in	New	York	,	...
B-ORG	I-ORG	O	O	O	O	B-LOC	I-LOC	O	...

Welche Features sind interessant, um über die Zugehörigkeit eines Wortes zu einer Named Entity zu entscheiden?

- ▶ **Wortform** ($X/x = \text{Groß/Kleinbuchstabe}$, $d = \text{Ziffer}$)

*"We announced the **TGX-42** today, which ..."*
→ $XXX-d$ (oder noch kürzer: $X-d$)

- ▶ **Präfixe/Suffixe** verschiedener Länge, z.B. $\mathbf{1}_{\text{suffix}(w)='ton'}$

*"He was in **distress**" vs. "He was in **Fartington**"*


- ▶ **POS-Tags**, auch benachbarter Worte, z.B.

$\mathbf{1}_{\text{POS}(w(-1))=\text{PREPOSITION}}$

*"...the CEO **of Google**..."*

- ▶ **Identität** von Worten, z.B. $\mathbf{1}_{w(+1)='said'}$
- ▶ Vorhandensein in Verzeichnis bekannter Namen
- ▶ ...

- ▶ Um den Term x_i zu labeln, poolen wir Features aus einem **lokalen Fenster** $x_{i-w}, \dots, x_{i-1}, x_i, x_{i+1}, \dots, x_{i+w}$
- ▶ Wir berücksichtigen außerdem die **Tags/Labels** der **Vorgängert Terme** t_{i-w}, \dots, t_{i-1}



Inferenz/Klassifikation von Sequenzen

- ▶ **Verfahren 1:** Klassifiziere jeden Term von links nach rechts, treffe für jeden Term eine harte lokale Entscheidung (*Greedy-Decoding*)
- ▶ **Verfahren 2:** Globale Optimierung mit Viterbi-Coding [1] (Kapitel 10)

References I



- [1] Daniel Jurafsky and James H. Martin.
Speech and Language Processing: An Introduction to Natural Language Processing (3rd Edition Draft Chapters).
2017.