

SEMINAR KLASSIFIKATION & CLUSTERING

EVALUIERUNG VON KLASSIFIKATOREN

Stefan Langer

stefan.langer@cis.uni-muenchen.de

Evaluierung

- Ziel: Vergleich unterschiedlicher Klassifizierungsalgorithmen und Parametersetzungen, Identifizierung der geeignetsten Klassifizierungsmethode
- Erforderlich: vorklassifizierte Daten (Trainingskorpus, Testkorpus)

Korpora zur Evaluierung

- Ein Korpus ist eine Sammlung von Texten, u.U. verbunden mit Metadaten
- In der CL interessieren wir uns in erster Linie für elektronische Korpora
- Für die Evaluierung von Textklassifikationsalgorithmen sind solche Korpora interessant, die bereits klassifiziert sind.
- Beispiele:
 - Zeitungskorpora mit Ressorts
 - Korpora bestimmter Texttypen

Vorstellung der verwendeten Korpora im Seminar

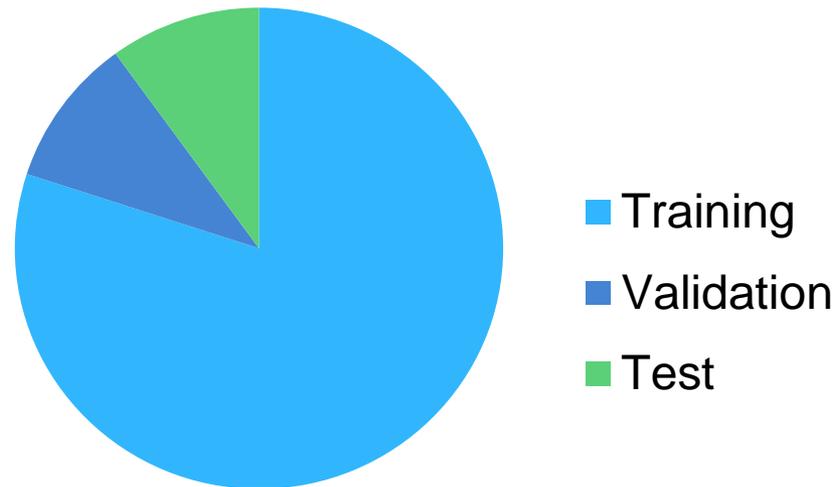
- Briefesammlung
- Huffington Post
- Sentiment

Manuelle Klassifikation

- Je nach Klassifikationsaufgabe sind die Abweichungen unterschiedlicher menschlicher Klassifizierer unterschiedlich hoch:
 - Sprachenerkennung – sehr gering
 - Themenzuordnung; Genrezuordnung Relevanzeinschätzungen: hoch.

Trainingskorpus - Testkorpus

- Für die Erstellung einer Anwendung muss das Korpus aufgeteilt werden in:
- Testkorpus
- Trainingskorpus
 - Evt. Training/Validation



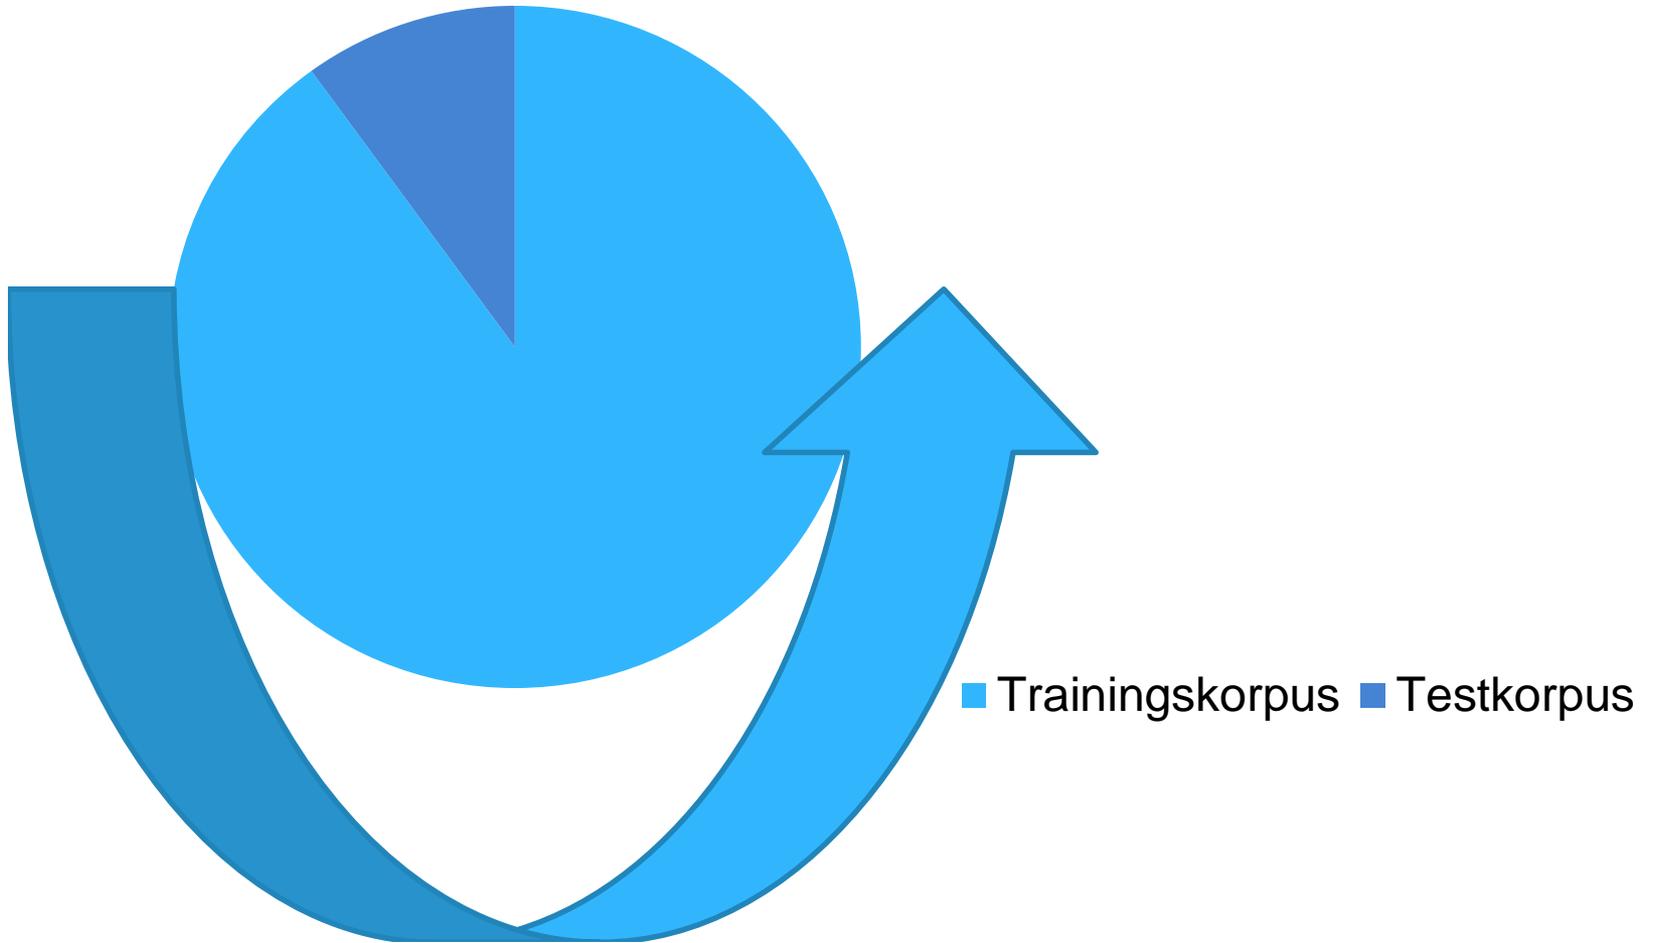
Terminologie

- Training: Zum Trainieren des Modells
- Validation: Optimierung von Hyperparametern oder Iterationskontrolle
- Test: Test auf dem endgültigen Modell

Verhältnis Testkorpus - Trainingskorpus

- i.d.R ist das Trainingskorpus wesentlich größer als das Testkorpus
- Ist das Korpus relativ klein, ist es möglich, Trainingsdaten und Testdaten zu rotieren

Cross validation



Classification report example

#Performance:

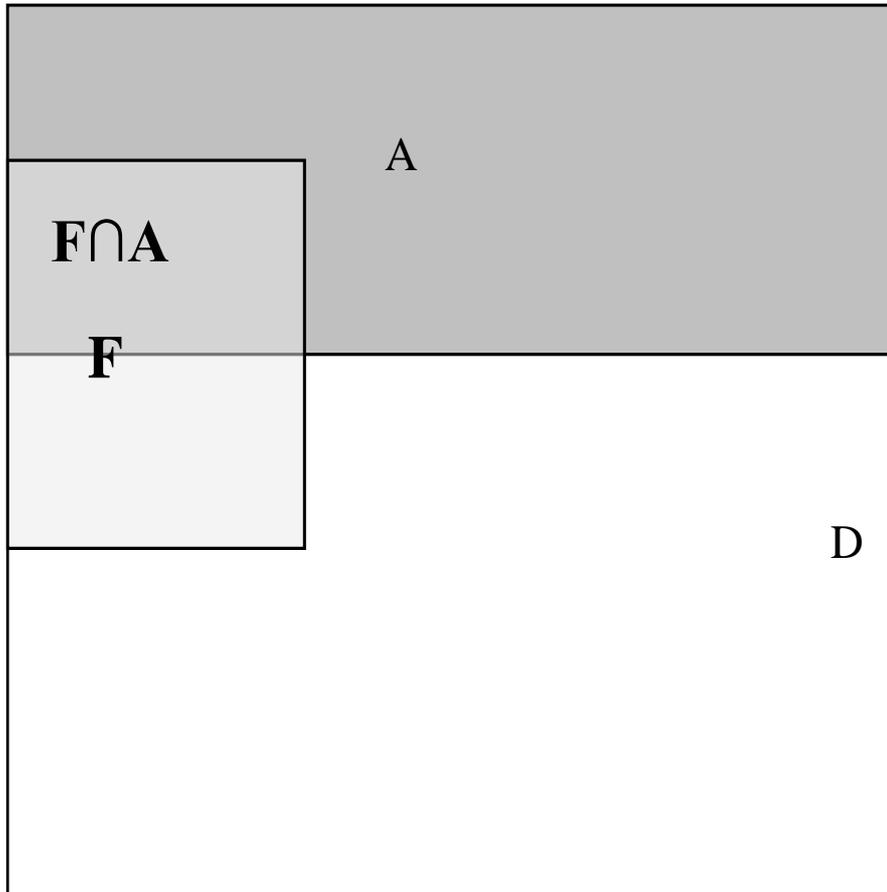
Seconds used for training: 55

Seconds used for classification: 12

#Classification report:

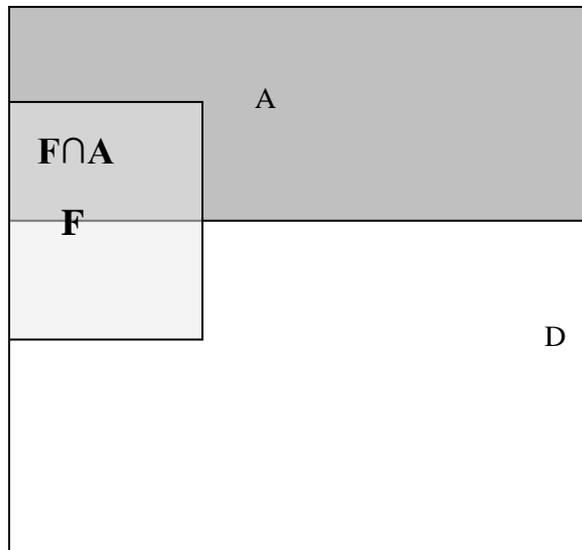
	precision	recall	f1-score	support
da	1.00	1.00	1.00	838
de	1.00	1.00	1.00	1443
en	1.00	1.00	1.00	2517
fr	0.92	1.00	0.96	36
it	0.94	0.94	0.94	31
unknown	0.70	0.44	0.54	16
accuracy			1.00	4881
macro avg	0.93	0.89	0.90	4881
weighted avg	1.00	1.00	1.00	4881

Trefferquote (Recall) und Genauigkeit (Precision)



- Maß für die Qualität des Retrievals
- D : Alle Dokumente
- A : Relevante Dokument
- F : Gefundene Dokumente
- $\text{Recall} = F \cap A / A$
- $\text{Precision} = F \cap A / F$

Übertragung von Precision und Recall auf die Evaluierung von Klassifikatoren



Berechnung pro Klasse

- D : Testset
- A : Dokumente, die zur Klasse gehören
- F : Der Klasse zugewiesene Dokumente
- $\text{Recall} = F \cap A / A$
- $\text{Precision} = F \cap A / F$

Berechnung von Recall und Precision für alle Klassen & Durchschnittsbildung

Mikro- vs. Makrobewertung

- Mikrobewertung:
 - Summiere für alle Klassen $|F \cap A|$, $|F|$ und $|A|$ auf
 - Ermittle Recall und Precision aus den Summen
- Makrobewertung
 - Ermittle Recall und Precision aus allen Klassen
 - Bilde den Mittelwert

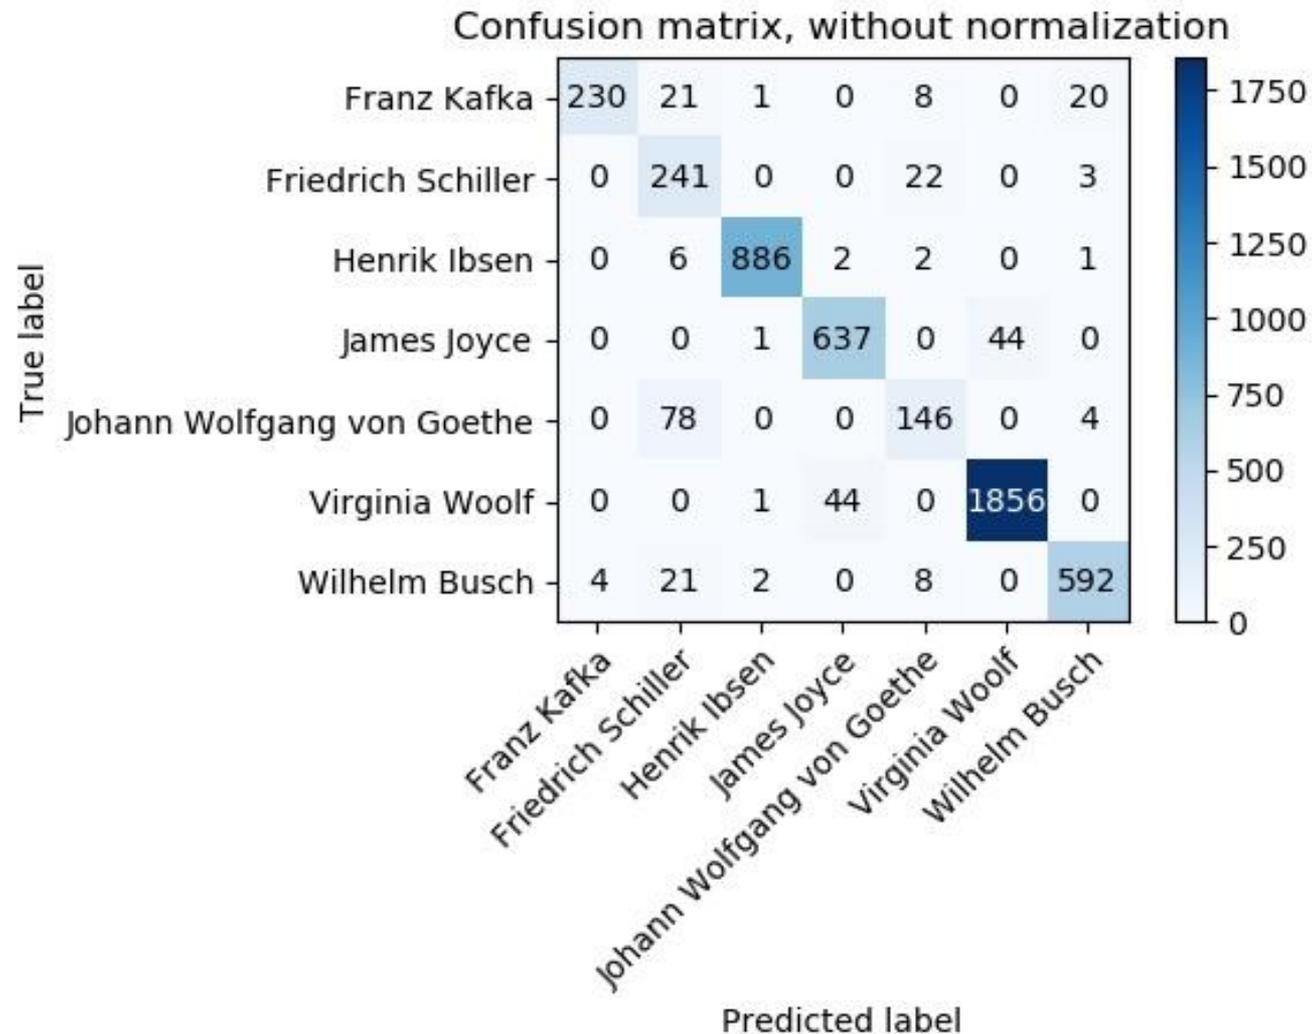
F-measure

$$\text{Fmeasure: } f = \frac{2 p * r}{p + r}$$

Hier ist p: Precision und r: Recall

(Harmonisches Mittel zwischen Precision und Recall)

Confusion matrix



Parameteroptimierung

- Grid search and randomized search
- Bayesian optimizers

Parameteroptimierung: Grid search

- Search pre-configured parameter settings
- In scikit-learn, pass as dictionary
 - E.g. random forest classifier:

```
parameter_grid = {  
    "criterion" : ["gini", "entropy"],  
    "max_depth" : [5, 10, 20, 40, 100, 200],  
    "min_samples_leaf" : [1, 2, 4, 8]  
}
```

- *Randomized search* is similar, but not alle possible values are used esp. useful for continuous parameter spaces

Evaluation: Clustering

- Interne/intrinsische Kriterien
 - Ähnlichkeit innerhalb des Clusters
 - Unähnlichkeit von Dokumenten in verschiedenen Clustern
 - Bsp. Silhouette-Koeffizient, Davies-Bouldin Index
- Externe Kriterien (z.B. Übereinstimmung mit vordefinierten Klassen)
 - Purity
- Direkte Evaluierung in Bezug auf den Use Case

Scikit-Learn

<https://scikit-learn.org/stable/modules/clustering.html#clustering-performance-evaluation>

Purity

$$\text{purity}(\Omega, \mathbf{C}) = \frac{1}{N} \sum_k \max_j |\omega_k \cap c_j|$$

Ω : Cluster

ω_k : Elemente in Cluster ω

\mathbf{C} : Klassen

c_j : Elemente in Klasse c

Quelle: Christopher D. Manning, Prabhakar Raghavan and Hinrich Schütze, Introduction to Information Retrieval, Cambridge University Press. 2008.

Andere externe Maße

- Normalized mutual information

Silhouettenkoeffizient

Silhouette des Clusterelements o , welches dem Cluster A zugeordnet ist, wobei

- B der nächstgelegene Cluster ist
- dist die mittlere Distanz zu den Elementen des Clusters

$$S(o) = \begin{cases} 0 & \text{wenn } o \text{ einziges Element von } A \text{ ist} \\ \frac{\text{dist}(B,o) - \text{dist}(A,o)}{\max\{\text{dist}(A,o), \text{dist}(B,o)\}} & \text{sonst} \end{cases}$$

Silhouettenkoeffizient eines Clusters C :

$$s_C = \frac{1}{n_C} \sum_{o \in C} s(o)$$

Quelle:
wikipedia