

Evaluation von Suchlösungen

::: MASTERSEMINAR SUCHMASCHINEN, CIS, SOMMERSEMESTER 2025 :::



Überblick

- Evaluation - Ziele
- Recall, Precision, F-Measure
- Mean average precision, precision at n
- DCG, NDCG

Suchmaschinen - Evaluierung

- In einer Suchlösung gibt es zahlreiche Parameter, u.a.:
 - - Welches Suchmaschine wird verwendet
 - - Vektorbasierte Suche versus Keyword-Suche
 - - Ranking-Formel
 - - Welche Embeddings werden verwendet
 - - Dokumentengewicht / Gewichtung einer Quelle
 - - Gewichtung von Dokumentabschnitten
 - - Queryvariationen (Proximity, Phrasensuche, Termgewichtung...)
 - - Stemming / Tokenisierung / Synonyme / Rechtschreibkorrektur


Um die verschiedenen Parameter einzustellen, müssen Evaluationskriterien definiert werden.

Suchmaschinenevaluierung - Daten

Evaluierung auf Basis von Referenzdaten

- Eine Menge von Anfragen aus der Anwendungsdomäne
 - Anfragen, die potentielle Benutzer*innen stellen könnten
 - Anfragen, die schon gestellt wurden (query logs)
 - Möglichst Abdeckung aller relevanten Bereiche
 - Einfache und komplexere Queries
- Ein Set von Dokumenten(-chunks) für jede Anfrage mit einem Relevanzmaß
 - Im einfachsten Fall: Passt/passt nicht (binär)
 - Besser: Geordnet nach Relevanz

Trefferquote (Recall) und Genauigkeit (Precision)



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

F-measure (F1 score)

F1 measure: $f = \frac{2 p * r}{p + r}$

Hier ist p: Precision und r: Recall

(Harmonisches Mittel zwischen Precision und Recall)


Generalisiert:

$$: f_{\beta} = \frac{(1 + \beta^2) p * r}{(\beta^2 p) + r}$$

Hier wird Recall (r) β -mal so stark gewichtet wie Precision


Probleme mit den bisher genannten Maßen

- Reihenfolge / Ranking spielt keine Rolle
 - In realistischen Szenarien werden nur die ersten Dokumente von den Benutzer*innen verarbeitet / angeschaut
- Schwer anwendbar auf größere Ergebnismengen
 - Relevante Dokumente müssen bekannt sein (für gesamte Ergebnismenge) um den Recall zu ermitteln
 - Dies ist in der Regel für größere Dokumentenmengen nicht der Fall



Average precision

- Average precision for all values of recall $r=0$ $r \leq 1$



Mean average precision

- Das Mittel der Average Precision über mehrere Queries

Die Maße Average Precision und Mean Average Precision:

- berücksichtigen das Ranking
- können nur berechnet werden, wenn der Recall feststeht

Precision bei k

- Anteil der relevanten Dokumente unter den ersten k Dokumenten
- Kann manuell kontrolliert werden auch bei größeren Dokumentenmengen
- Unabhängig vom Recall, kann daher ohne Kenntnis der gesamten Dokumentenmenge berechnet werden
- Beurteilung der Relevanz notwendig

Aber:

- keine Abhängigkeit von der Abfolge innerhalb der ersten k Dokumente

Gesucht – Maße für weitere Anwendungsfälle

Gegeben:

- Große Dokumentenmenge
 - Eine Liste von Anfragen (Queries)
 - Für jede Query sind einige sehr gute Dokumente bekannt und auch die gewünschte Reihenfolge der Dokumente, idealerweise die relevantesten Dokumente
- Realistisches Szenario für Evaluierung von Websuche, Intranetsuche (generell bei Suche über große Dokumentenmengen)

• **Evaluate your Recommendation Engine using NDCG - Towards ...**
<https://towardsdatascience.com/evaluate-your-recommendation-engine...>
Evaluate your Recommendation Engine using NDCG. How to best
Author: Pranay Chandekar

• **NDCG - What does NDCG stand for? The Free Dictionary**
<https://acronyms.thefreedictionary.com/NDCG>
Looking for online definition of NDCG or what NDCG stands

• **Evaluation measures (information retrieval) - Wikipedia**
[https://en.wikipedia.org/wiki/Evaluation_measures_\(information_retrieval\)](https://en.wikipedia.org/wiki/Evaluation_measures_(information_retrieval))
The nDCG values for all queries can be averaged to obtain a measure of the average performance of a ranking algorithm. Note.

• **A Theoretical Analysis of NDCG Ranking Measures**
proceedings.mlr.press/v30/Wang13.pdf · PDF file
NDCG has two advantages compared to many other measures. Page Count: 30
File Size: 612KB
Author: Yining Wang, Liwei Wang, Yuanzhi Li, Di He, Tie-Yan Liu

• **National Design & Craft Gallery, Kilkenny, Ireland - NDCG**
<https://www.ndcg.ie>
News 19 May ZOOM Seminar - Generation: Familial Legacies. 20

Mittlerer gegenseitiger Rang

(en: mean reciprocal rank)

- Gegeben:

- Eine Menge von Queries mit relevanten Dokumenten

- Verfahren

- Ermittle die Position p des ersten (bekannten) relevanten Dokuments in der Ergebnisliste für jede Query
- Der Rangwert ist $1/p$

- Der mittlere gegenseitige Rang ist der Mittelwert für den Satz von Queries

[CIS]

1. Centrale Intelligenz Systeme
2. Center for Information Security
-  3. Centrum für Informations- und Sprachverarbeitung
4. ...
5. ...

Reciprocal rank: $1/3$

CG, DCG

Discounted Cumulative Gain

Gegeben:

- Eine Menge von Queries mit relevanten Dokumenten, jedes Dokument hat einen Relevanzwert in Bezug auf die Query (der Relevanzwert ist ein beliebiger numerischer Wert, höher ist besser)

- CG: Summe der Relevanzwerte auf den ersten Positionen (bis Position p) der Trefferliste:

- $CG_p = \sum_{i=1}^p rel_i$

- DCG: Summe der Relevanzwerte auf den ersten Positionen der Trefferliste, höhere Positionen zählen mehr:

- $DCG_p = \sum_{i=1}^p \frac{rel_i}{\log_2(i+1)}$

NDCG

Normalized Discounted Cumulative Gain

Gegeben:

- (= DCG): Eine Menge von Queries mit relevanten Dokumenten, jedes Dokument hat einen Relevanzwert in Bezug auf die Query

- IDCG: Ideale Summe der Relevanzwerte auf den ersten Positionen (bis Position p) der Trefferliste:

- $IDCG_p = \sum_{i=1}^p rel_i$ | Ideal ordering by relevancy

- NDCG: DCG in Bezug auf den idealen DCG:

- $NDCG_p = \frac{DCG_p}{IDCG_p}$

NDCG Beispiel

Gegeben: Query “Fratercula arctica”. Kontext: Wikipedia Suche präferiert Sprache Deutsch

Dokumente mit Relevanz:

Dok	Relevanz	Position Ergebnis	Position ideal
https://de.wikipedia.org/wiki/Papageitaucher	1	2	1
https://de.wikipedia.org/wiki/Lunde	0.8	3	2
https://en.wikipedia.org/wiki/Atlantic_puffin	0.7	1	3
https://de.wikipedia.org/wiki/Skomer	0.6	7	4
https://de.wikipedia.org/wiki/Mingulay	0.6	4	5
https://nn.wikipedia.org/wiki/Lundefugl	0.3	5	6
https://de.wikipedia.org/wiki/Eulen	0	6	-

$$\text{IDCG}_6 = 2.45$$

$$\text{DCG}_6 = 2.1$$

$$\text{NDCG}_6 = 0.85$$

Online metrics (search engine usage)

Monitoring the search engine

- Number of results
- Zero-result rate

Monitoring user behaviour

- Click-through rate
- Session abandonment / session success rate

Feedback collection from users