



Maximilian Kähler

Evaluation im DNB-KI-Projekt

Drei ergänzende Wege zu einer besseren Beschlagwortung



Aspekte der Evaluation in ML-Projekten



Generalisierbarkeit von Evaluationsergebnissen

Generalisierbarkeit von Ergebnissen

Die Messtheorie unterscheidet systematische und zufällige Messfehler:

Beispiele systematischer Fehler:

- Verteilungsunterschiede zwischen Trainings- und Produktionsdaten¹
- "Information leakage" zwischen Trainings- und Evaluationsdaten

Beispiele zufälliger Fehler:

- Zufälliges Splitten von Trainings- und Evaluationsdaten
- "Unbekannte" in einem komplexen Datenentstehungsprozess


¹vgl. Toepfer M, Seifert C 2020; Fusion architectures for automatic subject indexing under concept drift;
<https://doi.org/10.1007/s00799-018-0240-3>

Generalisierbarkeit von Ergebnissen


- Systematische Fehler können nur von Fall-zu-Fall behandelt werden
- Zufällige Messfehler werden durch **Konfidenzintervalle** quantifiziert
- Zufällige Messfehler hängen von der Größe des Test-Sets, und von der „Variabilität der Daten“ ab

Beispiel: Quantifizieren von Unsicherheit durch Bootstrap-Konfidenzintervalle

Wiederholtes Berechnen der Zielmetrik durch zufälliges Resampling des Test-Sets führt zu veränderten Ergebnissen mit einer empirischen Verteilung X



Perzentile aus der Verteilung X können als Konfidenzintervalle verwendet werden, um die Unsicherheit durch zufällige Fehler zu quantifizieren




Dimensionen der Evaluation

Dimensionen der Evaluation

- Ziel-Metriken zur Gesamt-Qualität ermöglichen keine Rückschlüsse über Ursachen von guter bzw. schlechter Qualität
- Eine sinnvolle Evaluation muss „Drill-Down“-Analyse der Ergebnisse ermöglichen, um Hypothesen zur weiteren Optimierung der Verfahren zu generieren
- Wichtige Dimensionen der Auswertung müssen mit Domänen-Wissen und Algorithmen-Wissen diskutiert werden

Beispiel: Stratifizierung von Ergebnissen aus Sicht der Dokumente



Beispiel: Stratifizierung von Ergebnissen aus Sicht des Vokabulars



¹Models wurden mit annif.org erstellt

mllm:

Maii like lexical matching (vgl. annif.org)

Omikuji-bonsai:

Khandagale et al. 2016 "Bonsai: diverse and shallow trees for extreme multi-label classification"

Berücksichtigung von Auswertungsdimensionen bei der Erstellung von Test-Sets

- Auswertungsdimensionen müssen bedacht werden bevor Daten in Trainings- und Evaluations-Daten aufgeteilt werden
- Die Gesamtgröße des Test-Sets hängt von der gewünschten Genauigkeit und dem Konfidenzniveau der Zielmetrik ab. Ausschlaggebend ist das kleinste Stratum einer Auswertungsdimension
- Mit gerichteten Stichproben kann sichergestellt werden, dass alle Strata in allen Auswertungsdimensionen ausreichend im Test-Set vertreten sind

Summary: Where do we meet?

- Plan your evaluation scheme, before you start training models
- Discuss the dimensions of your data that need to be looked at
- Choose metrics that reflect your goals
- Discuss uncertainty and generalizability of your results

Vielen Dank!

Fragen und Anregungen jederzeit an:

Maximilian Kähler

E-Mail: m.kaehler@dnb.de

Unser DNB-KI-Projekt: <https://www.dnb.de/ki-projekt>

Related Work:

- **Golub etal 2016**; *A framework for evaluating automatic indexing or classification in the context of retrieval.* <https://doi.org/10.1002/asi.23600>
- **Raschka S 2020**; *Model Evaluation, Model Selection, and Algorithm Selection in Machine Learning.* <https://arxiv.org/abs/1811.12808v3>
- **Toepfer M, Seifert C 2018**; *Content-Based Quality Estimation for Automatic Subject Indexing of Short Texts Under Precision and Recall Constraints.* https://doi.org/10.1007/978-3-030-00066-0_1