

Vortrag zum Paper „Results of the Active Learning Challenge“ von Guyon, et. al.



TECHNISCHE
UNIVERSITÄT
DARMSTADT

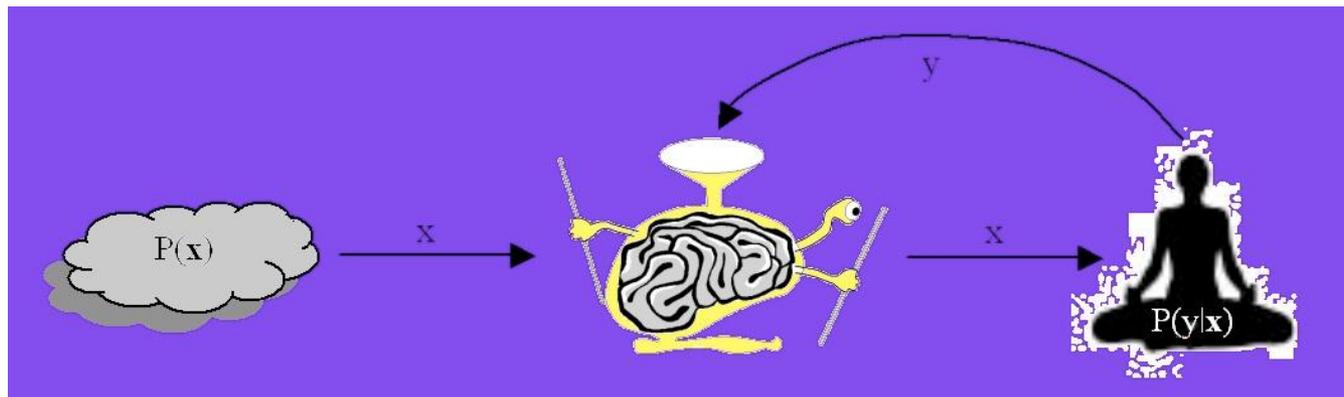
Sören Schmidt

Fachgebiet Knowledge Engineering



PASCAL2

Pattern Analysis, Statistical Modelling and
Computational Learning



Agenda

- 1) Einführung und Grundlagen
- 2) Beschreibung des Wettbewerbs
- 3) Übersicht der Ergebnisse
- 4) Eigenschaften der Ergebnisse
- 5) Fazit

Was ist Active Learning?

Passive Learning

- Trainings-Paare $\{x,y\}$ verfügbar
- Anzahl Trainings-Beispiele normal
- Spam Filter
- Warenkorbanalysen
- uvm.

Active Learning

- Große Menge an Trainings-Beispielen
- Label y jedoch zunächst unbekannt
- Cost of labeling (Orakel)
- Astronomie (Galaxien erkennen)
- Handschrifterkennung (Alte Schriften)
- Marketingdaten (CRM)
- Datenanalyse (Newsgroups)

Auswahlstrategien: Learning Machine „sollte“ diejenigen Beispiele auswählen / kaufen, die am vielversprechendsten aussehen (d.h. die predictive performance des Modells verbessern)

Active Learning Varianten:

- **Pool-based active learning:** Großer „Pool“ (Menge) von Beispielen ist verfügbar zum Training
- **Stream-based active learning:** Neue Beispiele kommen kontinuierlich im Stream
- **De-novo query synthesis:** Der Lerner kann für beliebige Werte von x das Label y abfragen. x muss nicht in $P(x)$ sein.

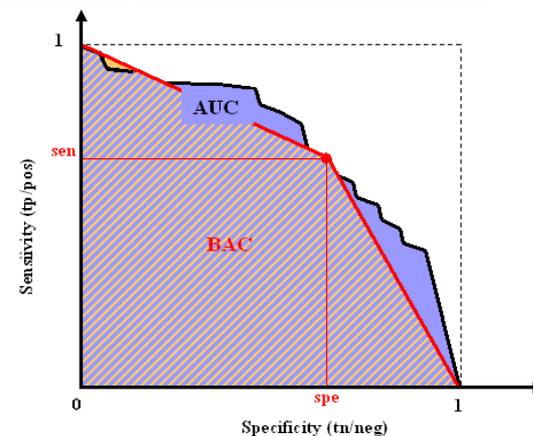
Wie evaluiert man einen Machine Learner?

| | Classified as + | Classified as - | |
|------|----------------------|----------------------|---------------|
| Is + | true positives (tp) | false negatives (fp) | $tp + fn = P$ |
| Is - | false positives (fp) | true negatives (tn) | $fp + tn = N$ |
| | $tp + fp$ | $fn + tn$ | $ E = P + N$ |

Confusion Matrix

Eigenschaften / Definitionen:

- Sensitivity (tp rate) = tp/P
- Specificity (tn rate) = tn/N
- fp rate = $1 - \text{spec}$

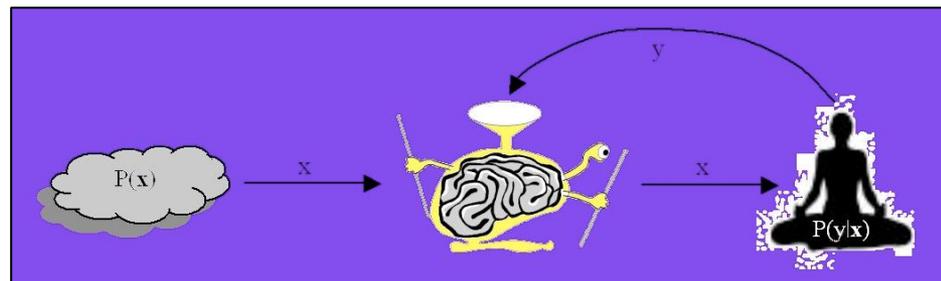


Agenda

- 1) Einführung und Grundlagen
- 2) Beschreibung des Wettbewerbs**
- 3) Übersicht der Ergebnisse
- 4) Eigenschaften der Ergebnisse
- 5) Fazit

Was ist die Active Learning Challenge?

- 2010 durchgeführter Machine Learning Wettbewerb
 - Annahme: labeling ist teuer (z.B. Expertenwissen)
 - Annahme: Große Mengen unlabeled data verfügbar
 - Annahme: Active learning zur Verbesserung der Vorhersage
- Modellierungs-Zielsetzung – predictive modeling: Gute Vorhersagen für fehlende Label
- Exponentieller Gewinner-Preis: $USD\ 100 \cdot 2^{(N-1)}$
 - Beim Gewinn von $N = \{1, 2, 3, 4, 5, 6\}$ Datensätzen können USD 100, 200, 400, 800, 1600, respektive 3200 gewonnen werden.



Wie lief der Wettbewerb ab?

Challenge Protocol:

- Für jeden Datensatz haben die Teams ein Budget von „virtual cash“ (*experimental cash unit, ECU*)
- Jeder Datensatz hat ein einziges Seed-Example/Label, das kostenlos ist
- Teams können Labels der unlabeled Trainingsdaten kaufen – für je 1 ECU pro Label
- Zum Kaufen von Labels muss ein Query mit der Liste an Beispielen an den Server geschickt werden, für den die Labels gekauft werden sollen
 - Beliebige Anzahl von Labels pro Query (innerhalb des Gesamtbudgets)
 - Gesamtbudget = Anzahl von Trainingsdaten - 1
- Experiment endet, wenn Budget aufgebraucht oder Zeit abgelaufen

Monitoring:

- Die Teams mussten bei jedem Query die aktuellen Vorhersagen aller Labels abgeben (unknown training examples und test examples)

Beschreibung des Wettbewerbs

Trainingsdatensätze (Development Dataset)



| Dataset | Feat. type | Feat. num. | Sparsity (%) | Missing (%) | Pos. lbls (%) | Tr & Te num. |
|----------|------------|------------|--------------|-------------|---------------|--------------|
| ALEX | binary | 11 | 0 | 0 | 72.98 | 5000 |
| HIVA | binary | 1617 | 90.88 | 0 | 3.52 | 21339 |
| IBN SINA | mixed | 92 | 80.67 | 0 | 37.84 | 10361 |
| NOVA | binary | 16969 | 99.67 | 0 | 28.45 | 9733 |
| ORANGE | mixed | 230 | 9.57 | 65.46 | 1.78 | 25000 |
| SYLVA | mixed | 216 | 77.88 | 0 | 6.15 | 72626 |
| ZEBRA | continuous | 154 | 0.04 | 0.0038 | 4.58 | 30744 |



Beschreibung des Wettbewerbs

Aufbau der Datensätze (Final Dataset)

| | Ft. 1 | Ft. 2 | Ft. 3 | ... | ... | ... | ... | ... | Ft. n | Label |
|----------------|-------|-------|-------|-----|-----|-----|-----|-----|-------|-------|
| Trainingsdaten | 0 | 1 | 0 | 0 | 0 | 1 | 1 | 0 | 0 | 1 |
| | 0 | 0 | 0 | 0 | 1 | 1 | 1 | 0 | 0 | ? |
| | 1 | 1 | 0 | 1 | 0 | 0 | 1 | 0 | 0 | ? |
| | 1 | 0 | 0 | 0 | 1 | 1 | 1 | 0 | 0 | ? |
| | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... |
| | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... |
| Testdaten | 0 | 1 | 0 | 0 | 0 | 1 | 1 | 0 | 0 | ? |
| | 0 | 0 | 0 | 0 | 1 | 1 | 1 | 0 | 0 | ? |
| | 1 | 1 | 0 | 1 | 0 | 0 | 1 | 0 | 0 | ? |
| | 1 | 0 | 0 | 0 | 1 | 1 | 1 | 0 | 0 | ? |

Seed Label

Query-able

to be predicted



$$\text{global_score} = (\text{ALC} - \text{Arand}) / (\text{Amax} - \text{Arand})$$

- **ALC = Area under the Learning Curve**

- ALC trägt die AUC (Area under the ROC curve) für alle unbekanntem Labels als Funktion der Anzahl gekaufter Labels ab

- **Amax = Area maximum**

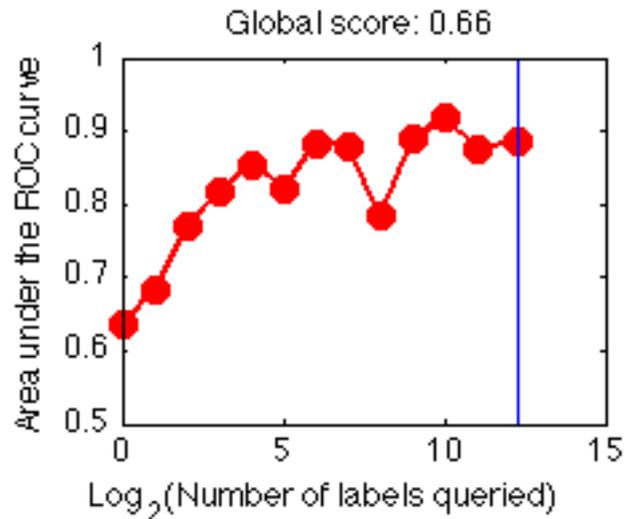
- Ideale Learning Curve, perfekte Vorhersagen (AUC = 1)

- **Arand = Area random**

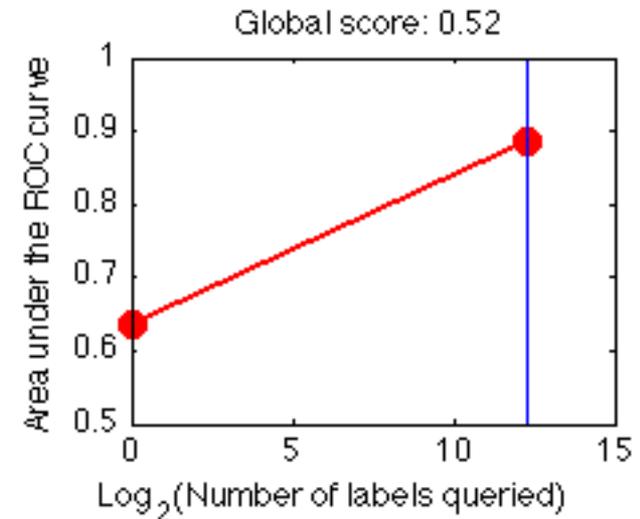
- Lazy Learning Curve, zufällige Vorhersagen (AUC \approx 0.5)

Zwei
Baseline
Kurven





Random Sampling



Passive Learning

Eigenschaften

- Logarithmische X-Achse
- AUC > 0.5
- Ende bei log(# of Trainingsbeispiele)

Agenda

- 1) Einführung und Grundlagen
- 2) Beschreibung des Wettbewerbs
- 3) Übersicht der Ergebnisse**
- 4) Eigenschaften der Ergebnisse
- 5) Fazit

Baseline Resultate (Bechmarks / Referenzen)

| Dataset | Experiment | Classifier | Strategy | AUC | ALC | Rank |
|----------|-------------|-------------|----------|----------|----------|------|
| HIVA | gcchiva4 | Naïve Bayes | Bayesian | 0.805504 | 0.328535 | — |
| IBN_SINA | gccibnsina1 | Linear KRR | Random | 0.978585 | 0.813690 | — |
| NOVA | gccnova1 | Linear KRR | Random | 0.991841 | 0.715582 | — |
| ORANGE | gccorangel | Linear KRR | Random | 0.814340 | 0.283319 | — |
| SYLVA | gccsylva1 | Linear KRR | Random | 0.996240 | 0.921228 | — |
| ZEBRA | gcczebra1 | Linear KRR | Random | 0.785913 | 0.416948 | — |
| Avicena | gccA004v | Linear KRR | Random | 0.883768 | 0.586001 | 3 |
| Banana | gccb1 | Linear KRR | Passive | 0.720291 | 0.370762 | 3 |
| Chemo | gcc4 | Linear KRR | Random | 0.814450 | 0.301776 | 5 |
| Docs | gccd2 | Linear KRR | Random | 0.962951 | 0.651222 | 6 |
| Embryo | gccel | Linear KRR | Passive | 0.773262 | 0.496610 | 5 |
| Forest | gccf2 | Linear KRR | Random | 0.954557 | 0.821711 | 1 |

- Einfacher Ansatz / Klassifizierer
 - Komplexere nicht-lineare Methods (decision tree, SVM, naive Bayes,...) nicht verwendet
 - Gefahr von over-fitting; Linear KRR weniger over-fitting (Wahl des Rigid Parameter)
- Einfache Sampling Strategien
 - Passive learning (Query aller Labels auf einmal) und random learning bringen gute Resultate
- Sehr gute Resultate (avg. Rank = 3.833) – Selection-Bias

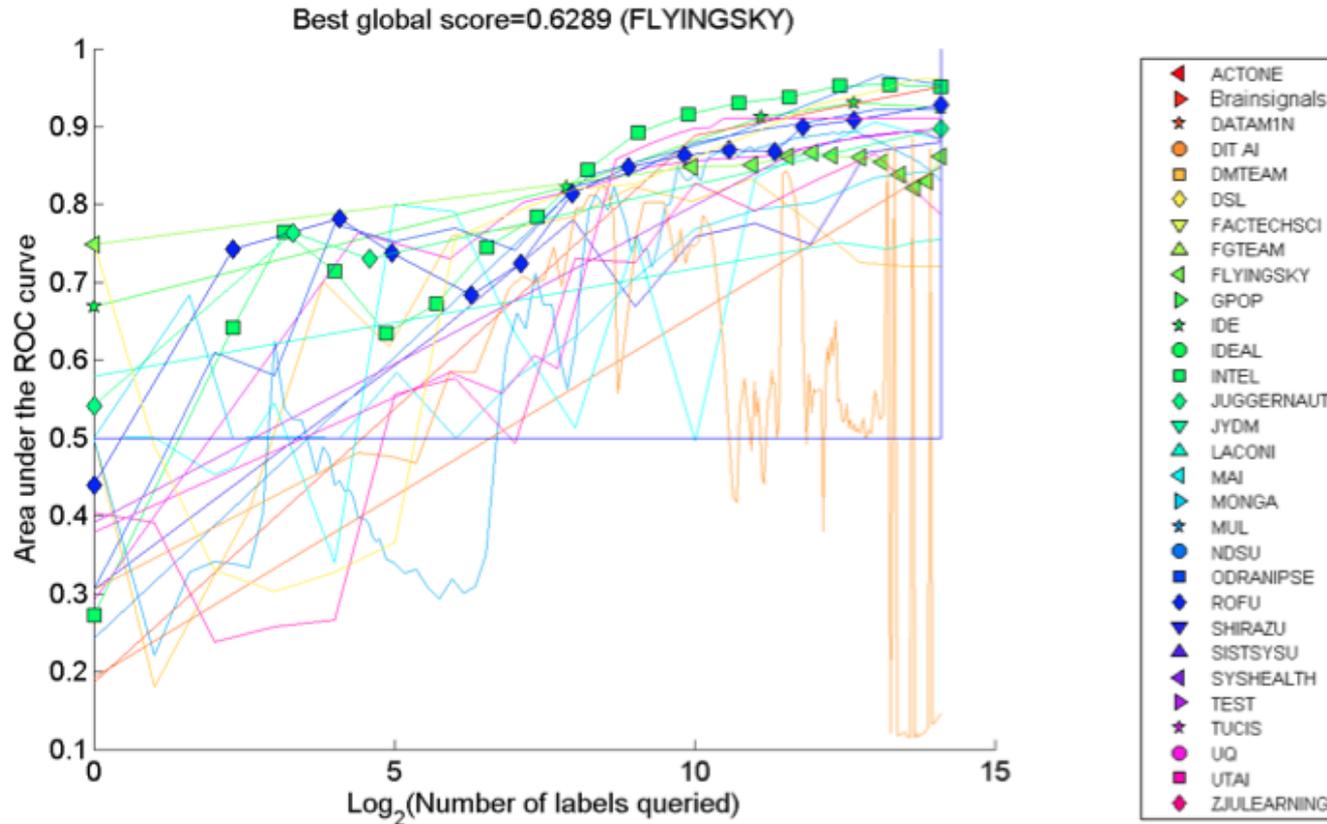


Figure 2: *Learning curves for dataset A.*



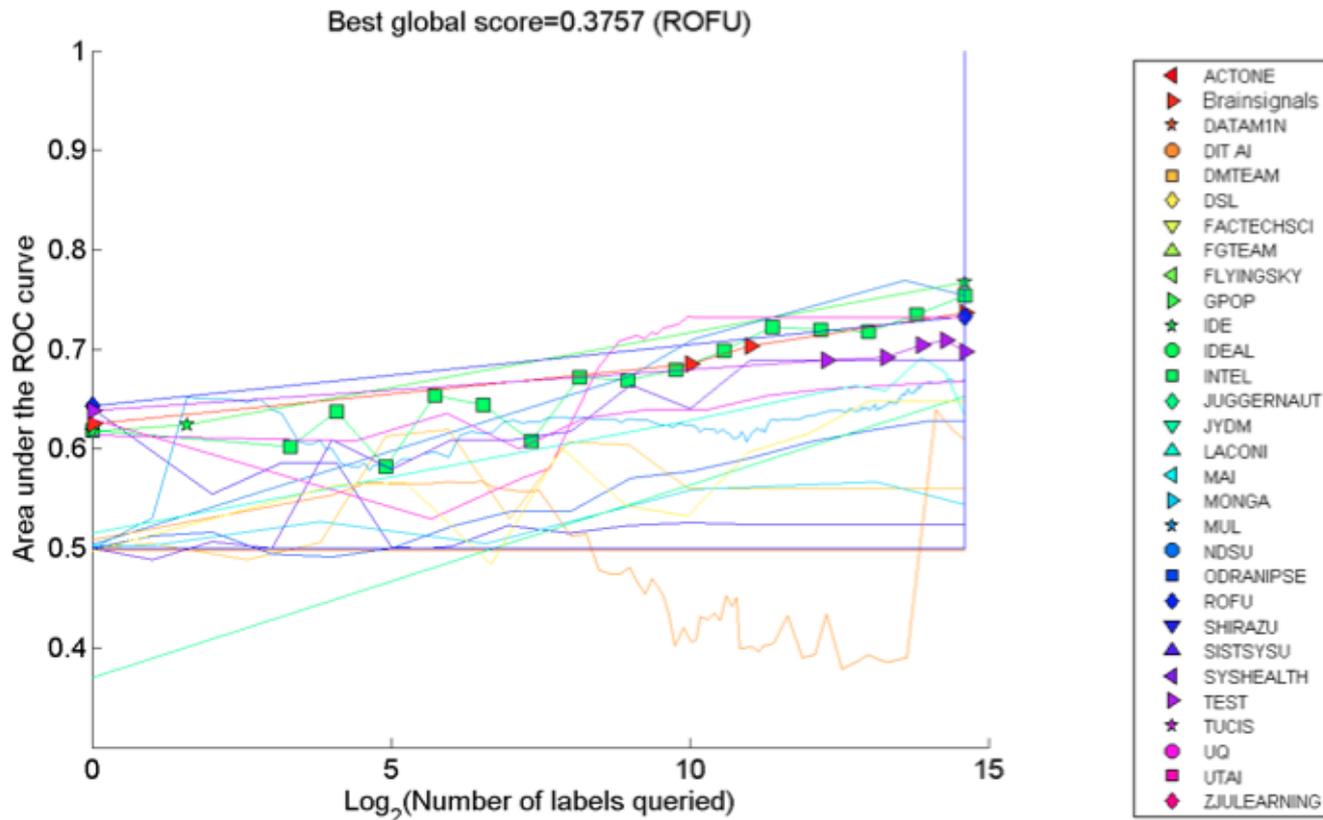


Figure 3: *Learning curves for dataset B.*



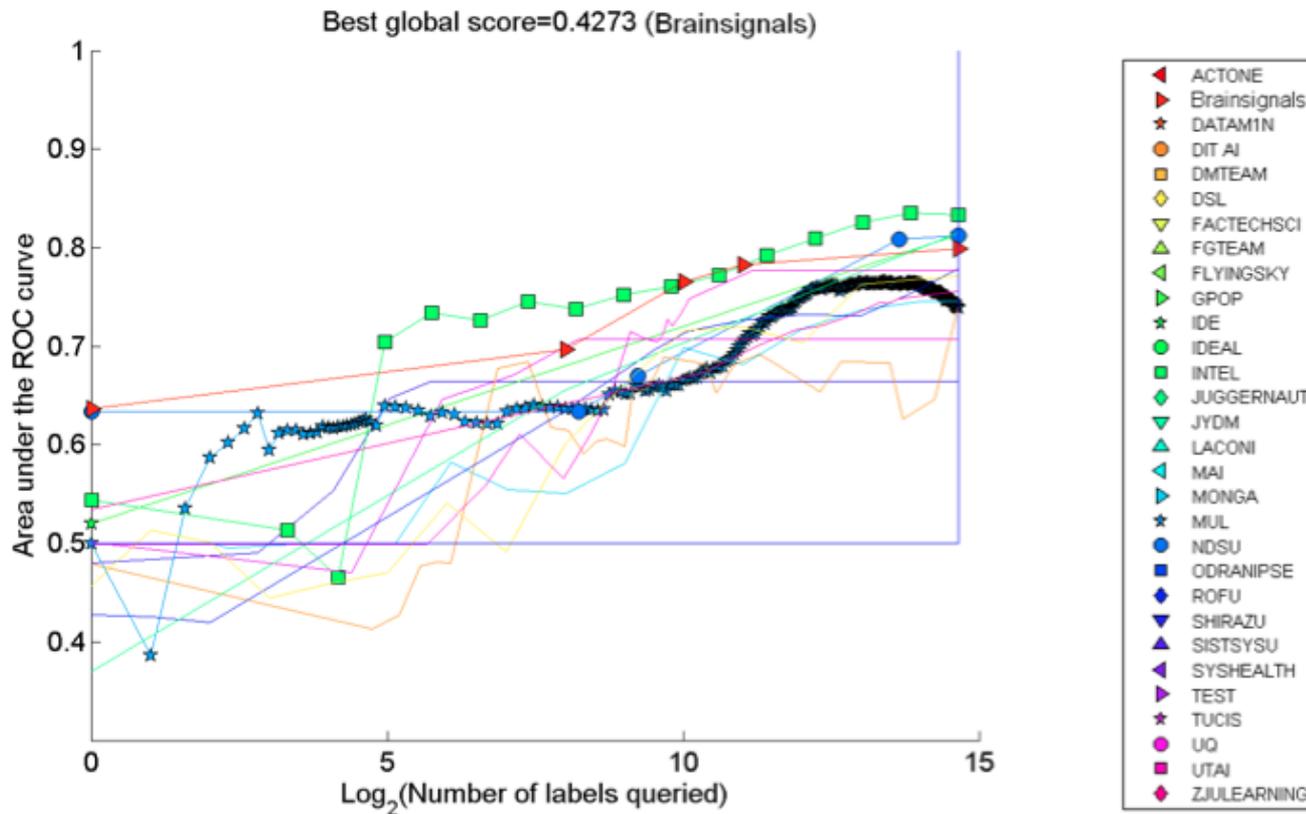


Figure 4: Learning curves for dataset C.

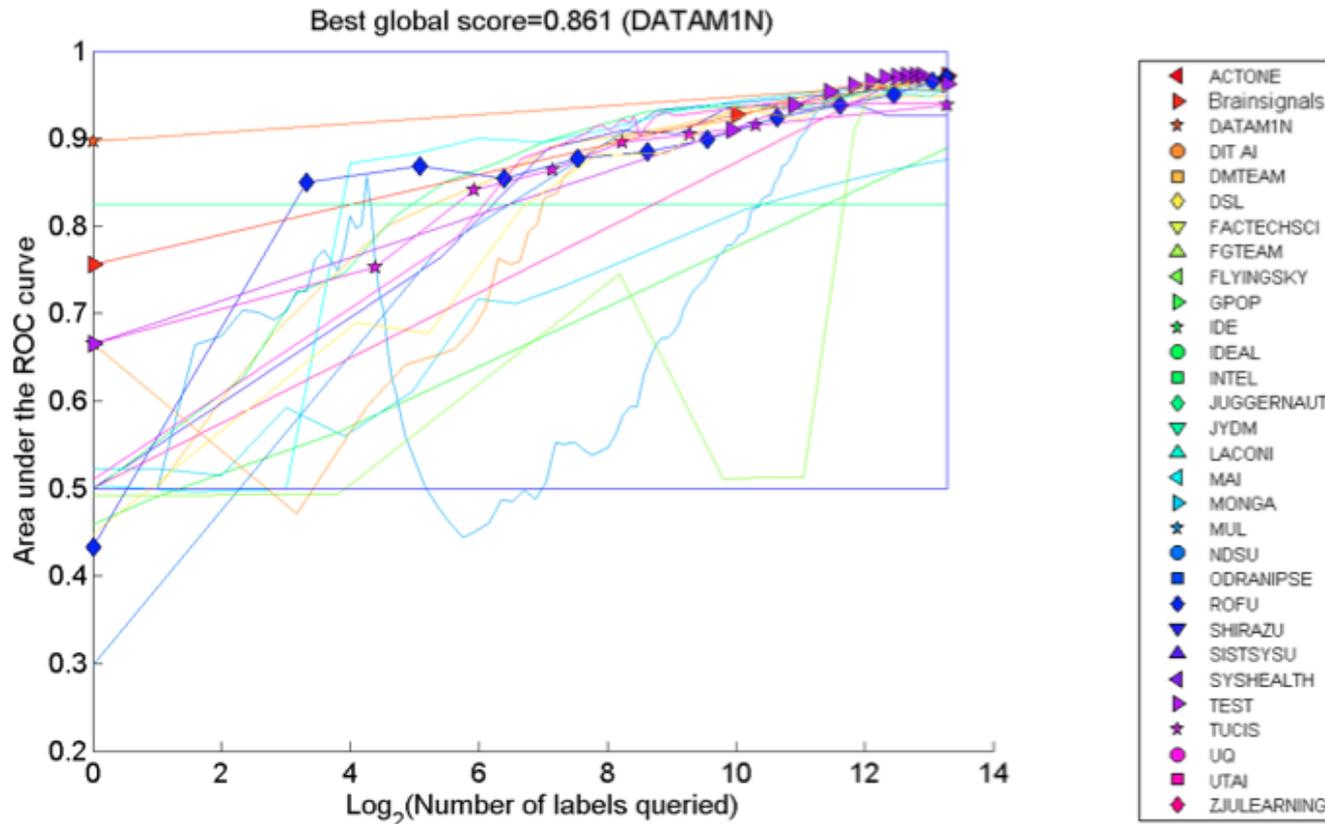


Figure 5: *Learning curves for dataset D.*

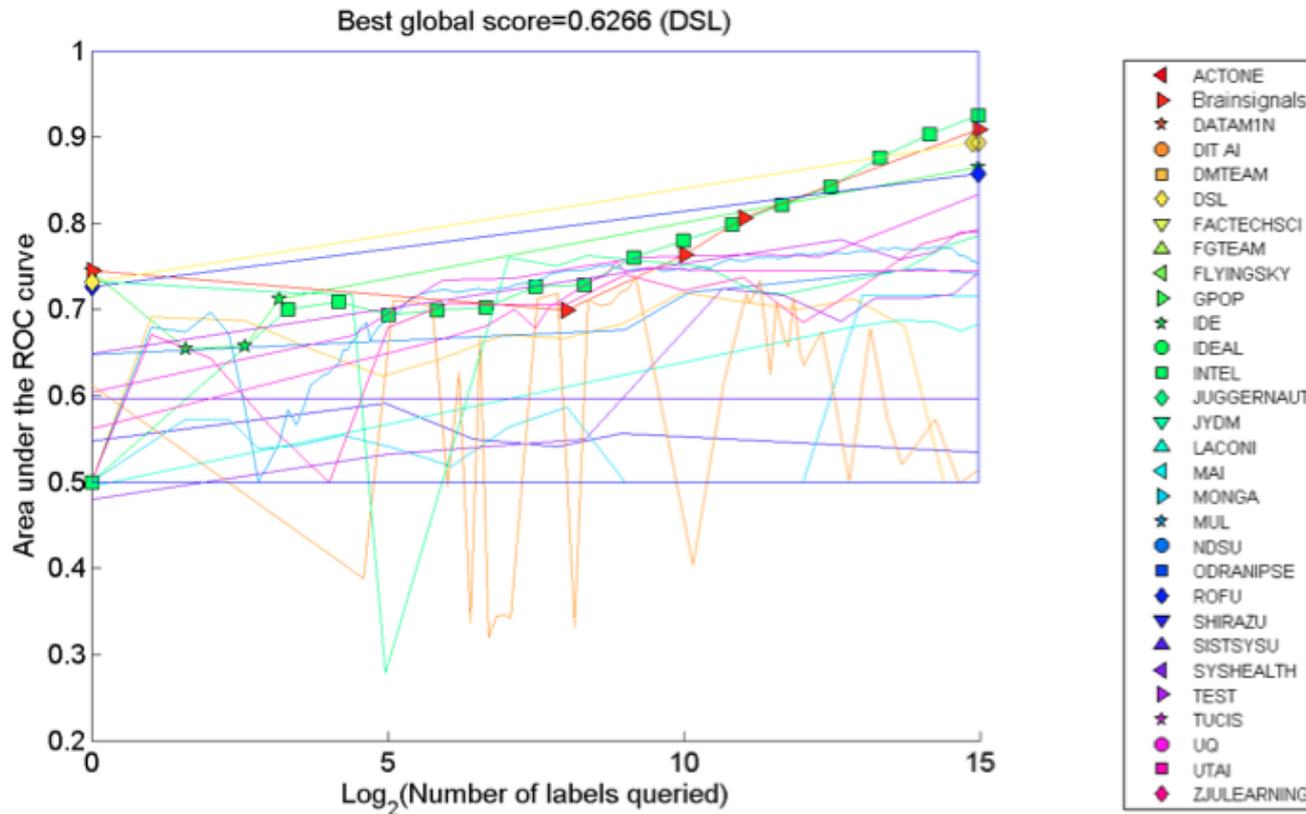


Figure 6: *Learning curves for dataset E.*

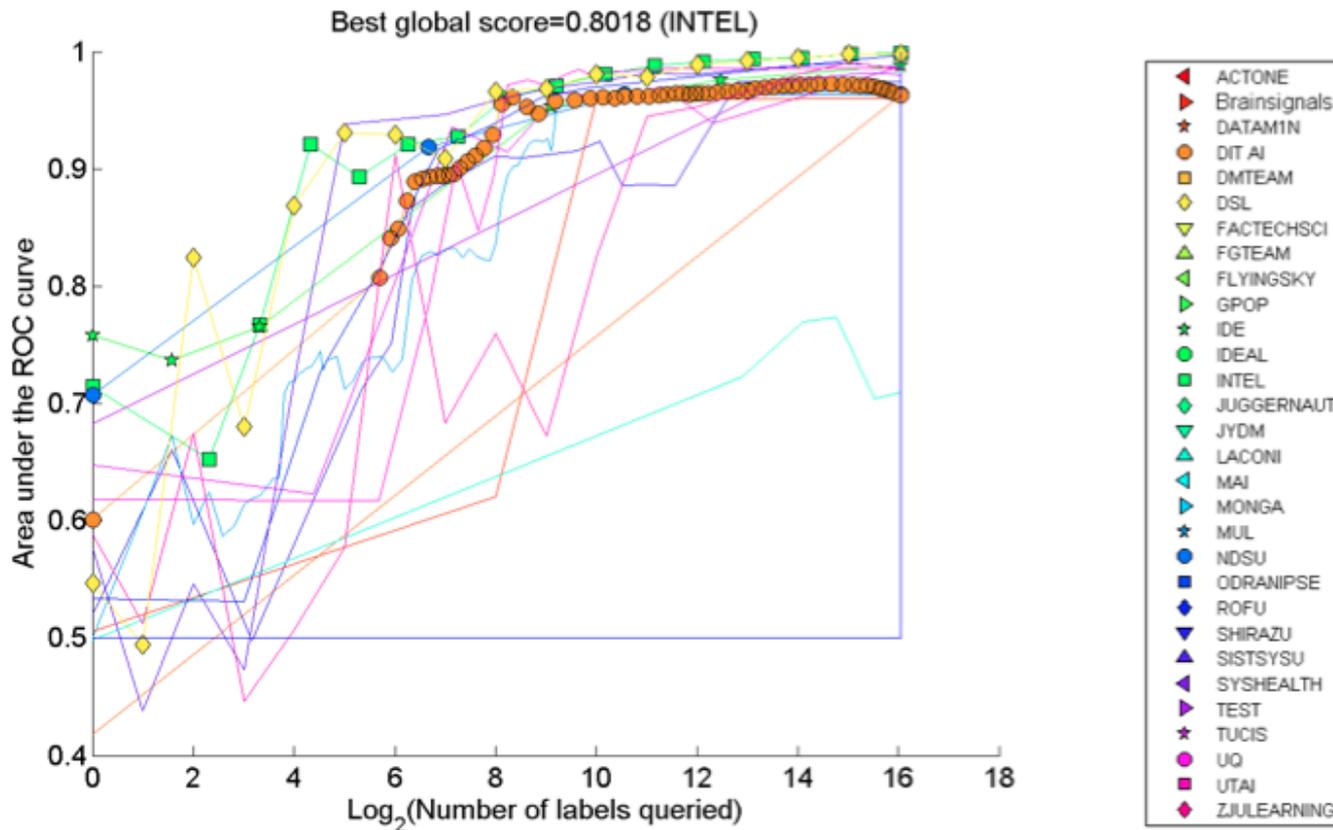


Figure 7: *Learning curves for dataset F.*



Agenda



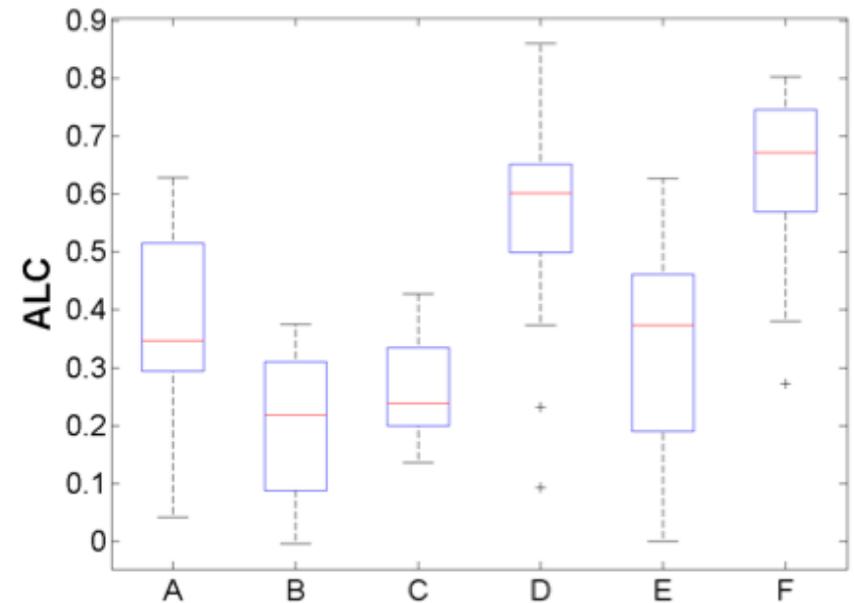
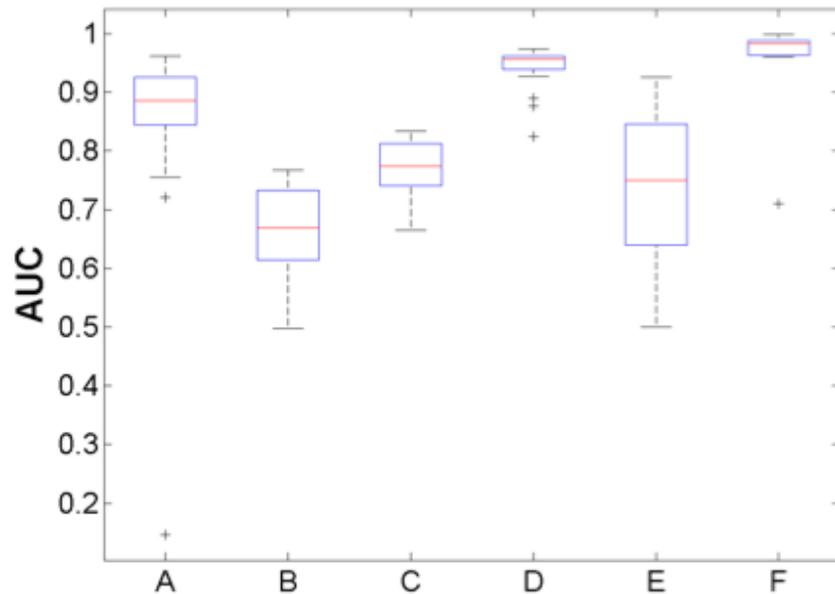
TECHNISCHE
UNIVERSITÄT
DARMSTADT

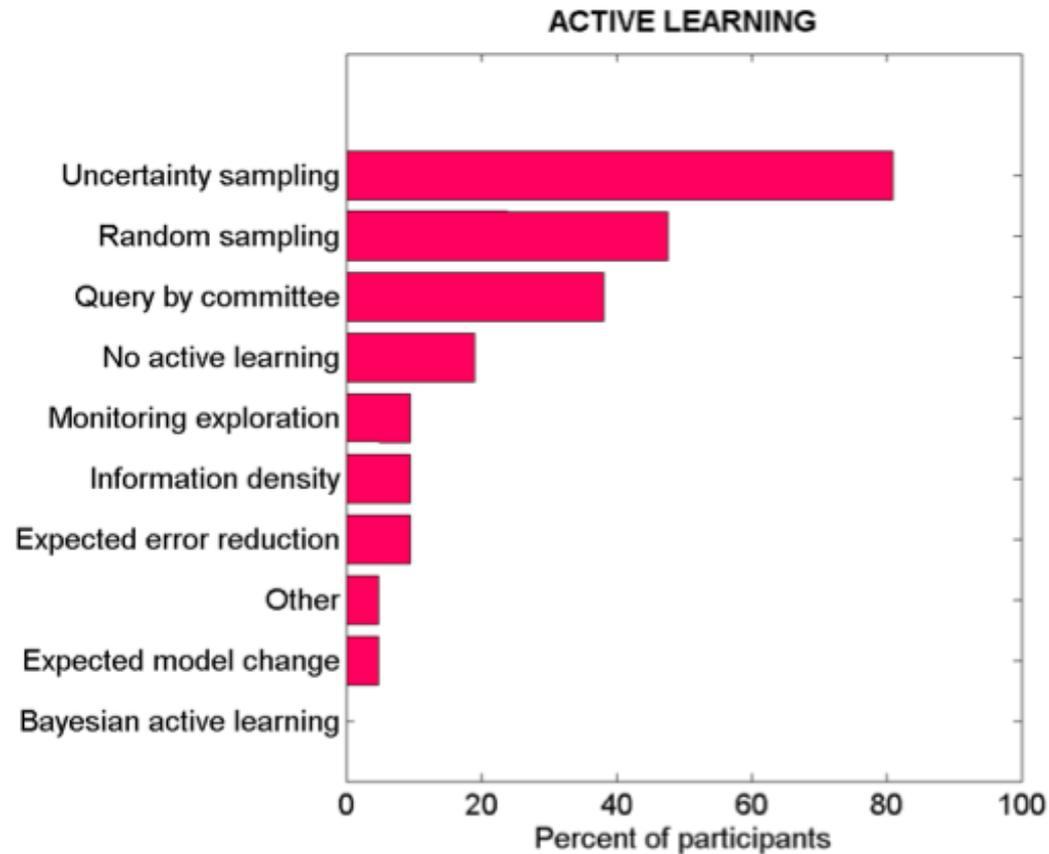
- 1) Einführung und Grundlagen
- 2) Beschreibung des Wettbewerbs
- 3) Übersicht der Ergebnisse
- 4) Eigenschaften der Ergebnisse**
- 5) Fazit

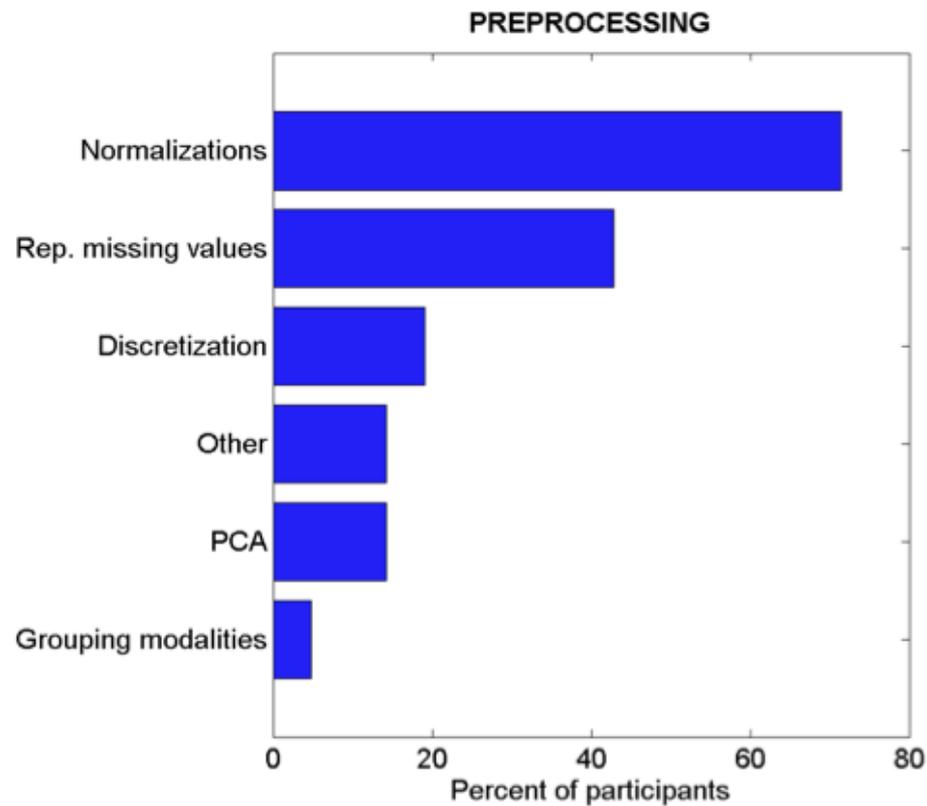


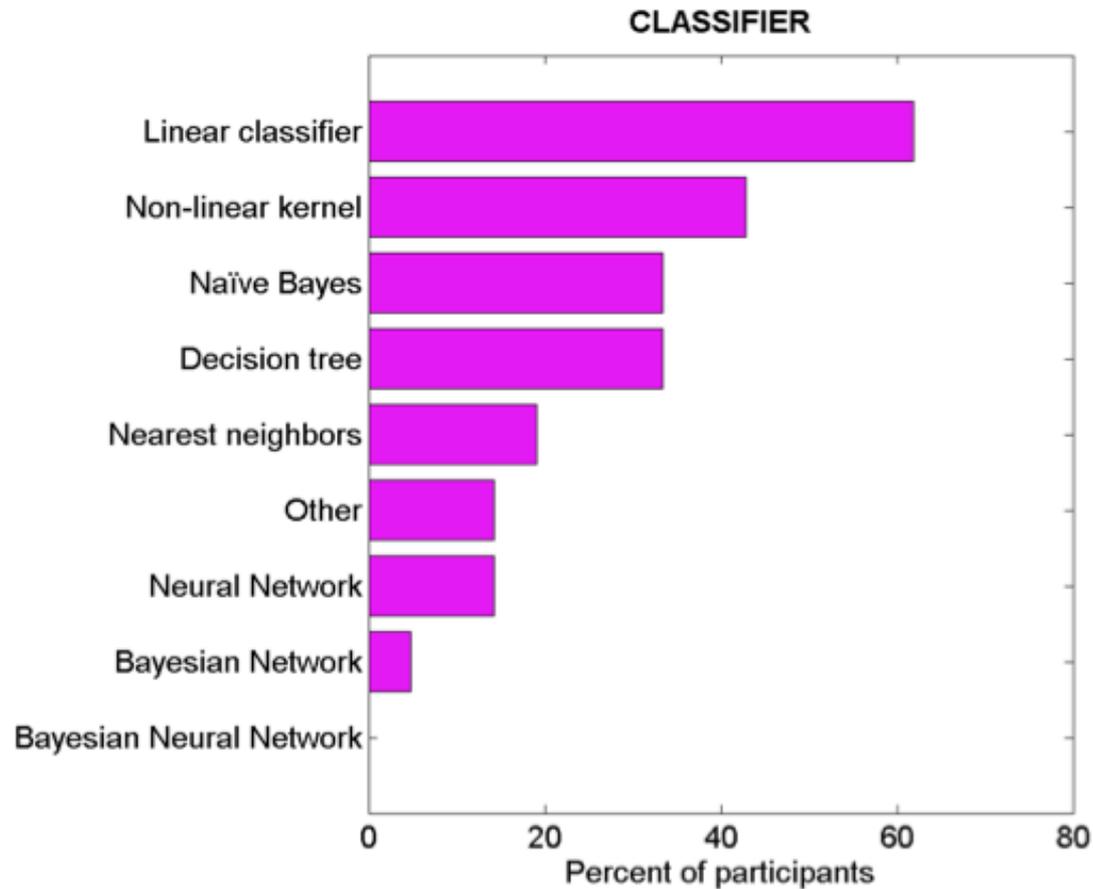
Eigenschaften der Ergebnisse

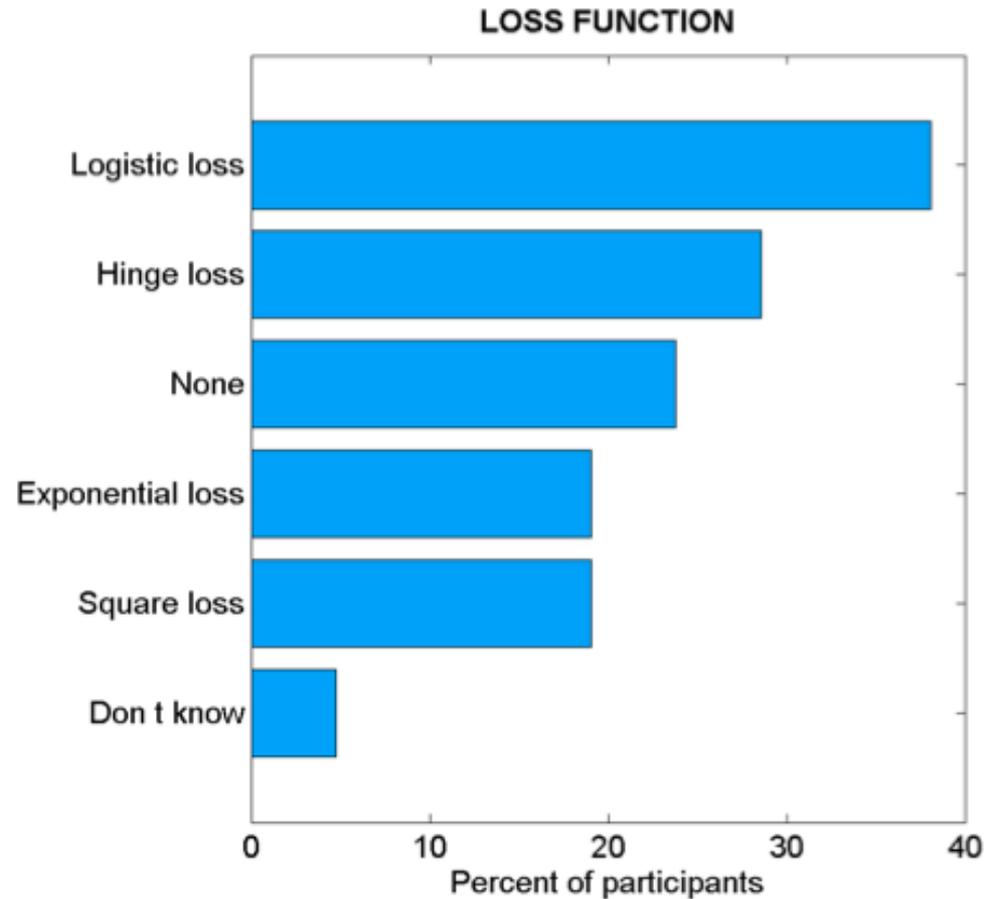
Verteilung der Ergebnisse











Agenda



TECHNISCHE
UNIVERSITÄT
DARMSTADT

- 1) Einführung und Grundlagen
- 2) Beschreibung des Wettbewerbs
- 3) Übersicht der Ergebnisse
- 4) Eigenschaften der Ergebnisse
- 5) **Fazit**





- Mehr als 300 Teilnehmer registriert (Development Phase)
- Mehr als 30 Teams für die Test-Phase
 - Teamgröße zwischen 1 und 20
 - 50% der Teams haben länger als 2 Wochen „programmiert“
- Kein Team hat mehr als ein Datenset gewonnen
- Overall ranking:
 - 1st: Intel team avg. rank 4.2
 - 2nd: RUFO team avg. rank 4.8
 - 3rd: IDE team avg. rank 5.7





Table 4: Result tables for the top ranking teams.

| Dataset A | | | Dataset B | | |
|------------|-----------------|--------|--------------|-----------------|--------|
| Team | AUC (Ebar) | ALC | Team | AUC (Ebar) | ALC |
| Flyingsky | 0.8622 (0.0049) | 0.6289 | ROFU | 0.7327 (0.0034) | 0.3757 |
| IDE | 0.9250 (0.0044) | 0.6040 | IDE | 0.7670 (0.0038) | 0.3754 |
| ROFU | 0.9281 (0.0040) | 0.5533 | Brainsignals | 0.7367 (0.0043) | 0.3481 |
| JUGGERNAUT | 0.8977 (0.0036) | 0.5410 | TEST | 0.6980 (0.0044) | 0.3383 |
| Intel | 0.9520 (0.0045) | 0.5273 | Intel | 0.7544 (0.0044) | 0.3173 |

| Dataset C | | | Dataset D | | |
|--------------|-----------------|--------|--------------|-----------------|--------|
| Team | AUC (Ebar) | ALC | Team | AUC (Ebar) | ALC |
| Brainsignals | 0.7994 (0.0053) | 0.4273 | DATAM1N | 0.9641 (0.0033) | 0.8610 |
| Intel | 0.8333 (0.0050) | 0.3806 | Brainsignals | 0.9717 (0.0033) | 0.7373 |
| NDSU | 0.8124 (0.0050) | 0.3583 | ROFU | 0.9701 (0.0032) | 0.6618 |
| IDE | 0.8137 (0.0051) | 0.3341 | TEST | 0.9623 (0.0033) | 0.6576 |
| MUL | 0.7387 (0.0053) | 0.2840 | TUCIS | 0.9385 (0.0037) | 0.6519 |

| Dataset E | | | Dataset F | | |
|--------------|-----------------|--------|-----------|-----------------|--------|
| Team | AUC (Ebar) | ALC | Team | AUC (Ebar) | ALC |
| DSL | 0.8939 (0.0039) | 0.6266 | Intel | 0.9990 (0.0009) | 0.8018 |
| ROFU | 0.8573 (0.0043) | 0.5838 | NDSU | 0.9634 (0.0018) | 0.7912 |
| IDE | 0.8650 (0.0042) | 0.5329 | DSL | 0.9976 (0.0009) | 0.7853 |
| Brainsignals | 0.9090 (0.0039) | 0.5267 | IDE | 0.9883 (0.0013) | 0.7714 |
| Intel | 0.9253 (0.0037) | 0.4731 | DIT AI | 0.9627 (0.0017) | 0.7216 |





Uncertainty sampling
und query-by-
committee
(ohne randomness)
schneiden schlechter
ab als random
sampling

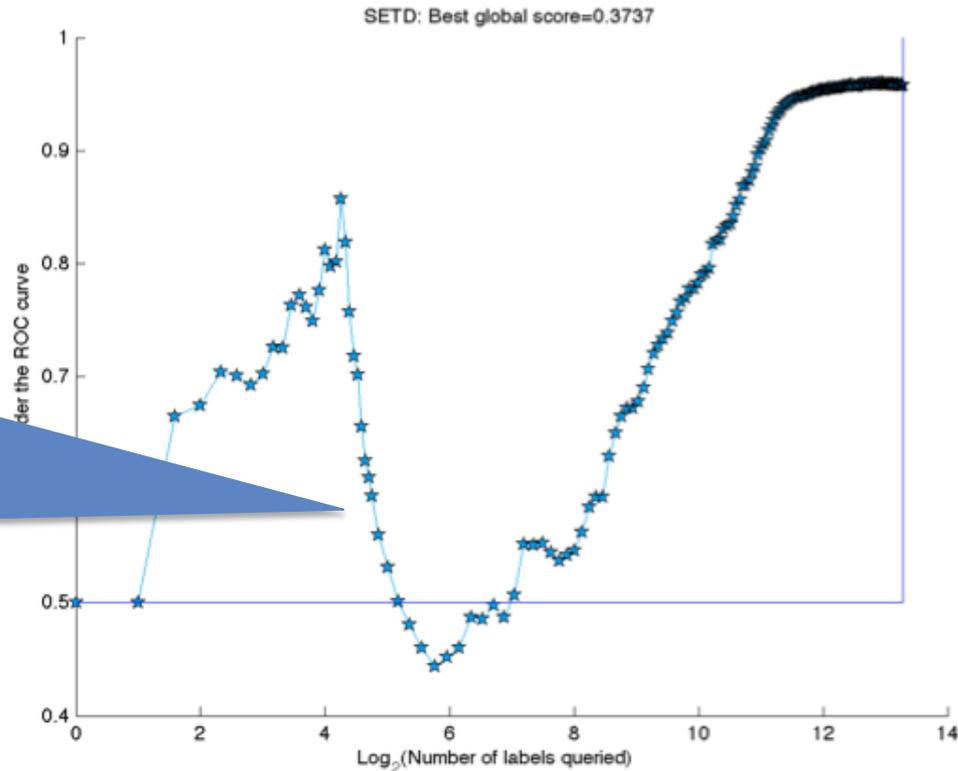
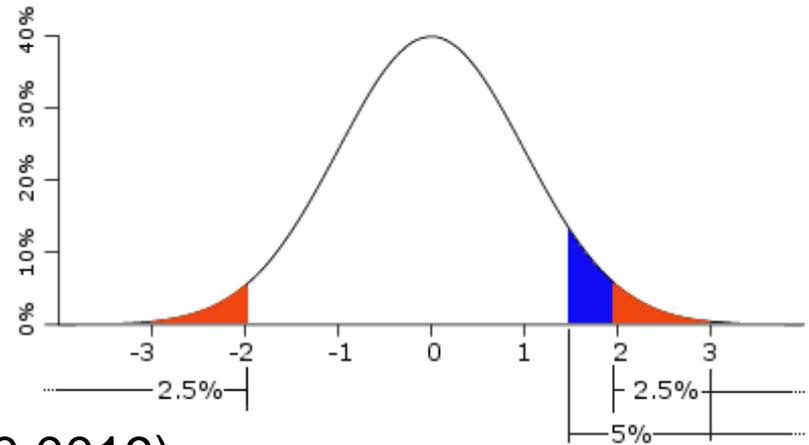


Figure 8: *Example of learning curves for dataset D using the uncertainty sampling strategy.*

Gibt es signifikante Aussagen?

- **top ranked vs. lowest ranked**
- Friedman test
 - Avg. Platzierungen je Dataset
 - H_0 : Average ist gleich
 - Full-Score-Matrix notwendig

→ Hoch signifikant! (P-value: 0.0019)



- **Unterschiede zwischen Algorithmus A und allen anderen**
- Nemenyi test (post-hoc)
 - Nur das erste (Intel) und letzte (DIT AI) sind signifikant unterschiedlich



- **Ziel: Decoupling**
- Learning Strategie vom Klassifizierer unabhängig
 - Random sampling (passive learning)
- 10 Durchläufe (Varianzreduktion)
- **Resultat:**
 - Tree Klassifizierer eher schlecht (vor allem am Anfang)
 - Ensemble of Trees sind gut
 - **Generativ (naive Bayes) besser als Discriminativ (am Anfang)**

→ Wahl des Klassifizierers wohl wichtiger als Active Learning Strategie



- Hohe Teilnahme, trotz Komplexität
- Viele verschiedene Techniken ausprobiert
- Eher explorativ: Learn-Strategie und Klassifizierer wurden vermischt
 - Müsstenxw getrennt betrachtet werden
- Wahl des Klassifizierers sehr wichtig
 - Strategien zur Klassifizierer-Wahl je nach Anzahl an Examples
- Semi-supervised learning am Anfang der Lernkurve (Seed)
- Randomisierung notwendig, um gute Resultate zu erreichen (over-fitting)
- → Active Learning Strategien müssen noch intensiver untersucht werden

Danke!



TECHNISCHE
UNIVERSITÄT
DARMSTADT



Danke für die Aufmerksamkeit!