University of Basel

LLM-Benchmarking für die Digital Humanities

Ein praxisorientierter Ansatz aus der Forschungsberatung

Dr. Maximilian Hindermann (RISE & UB Basel) 11.11.2025

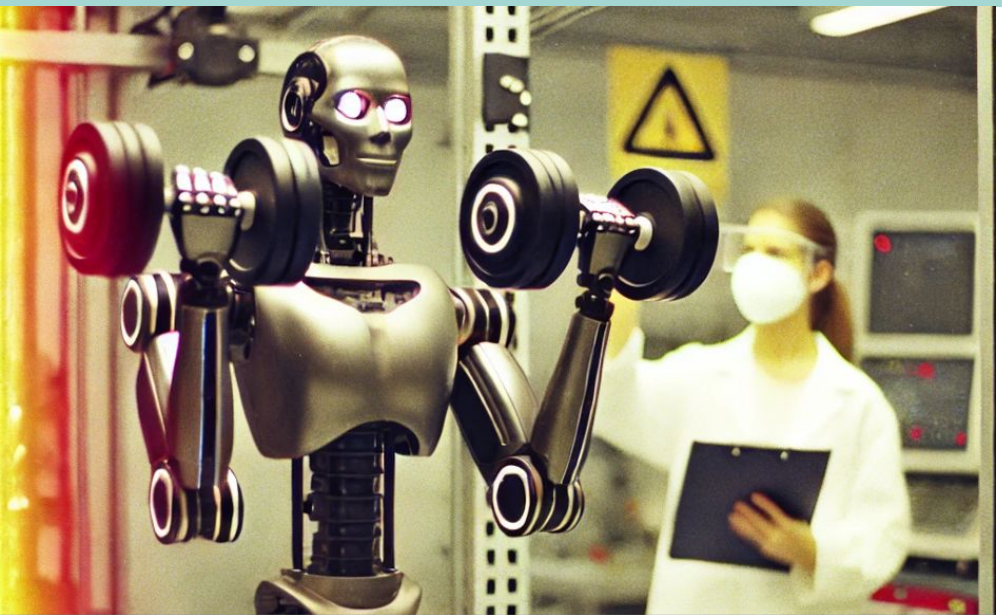

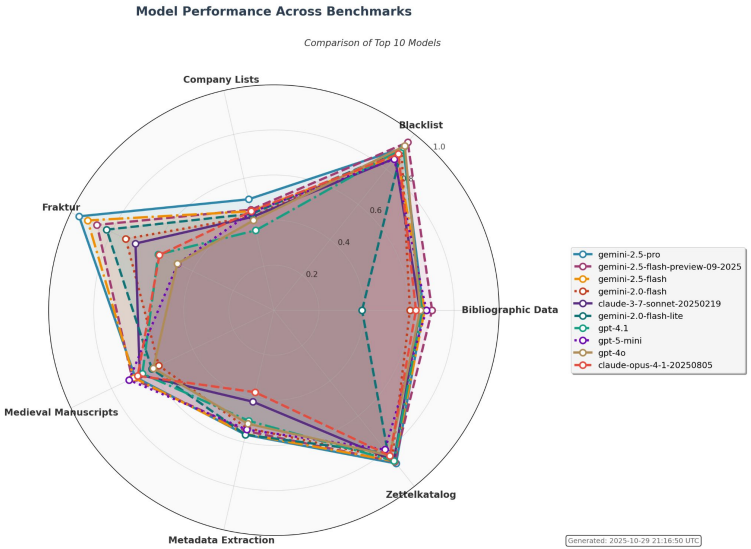

Programm

1. Benchmarking als epistemische Praxis
2. RISE Humanities Data Benchmark
3. Live Demo
4. Herausforderungen, Learnings und Ausblick
5. Fragen & Diskussion

Research and Infrastructure Support (RISE)

“Wir unterstützen Forscherinnen und Forscher in den Geistes- und Sozialwissenschaften an der Universität Basel bei Fragen der Konzeption computergestützter Forschung, der Herstellung, Analyse und nutzungsorientierten Darstellung von digitalen Daten, sowie deren nachhaltiger und offener Verfügbarmachung.”
https://rise.unibas.ch

Forschungsprojekte verwenden LLMs

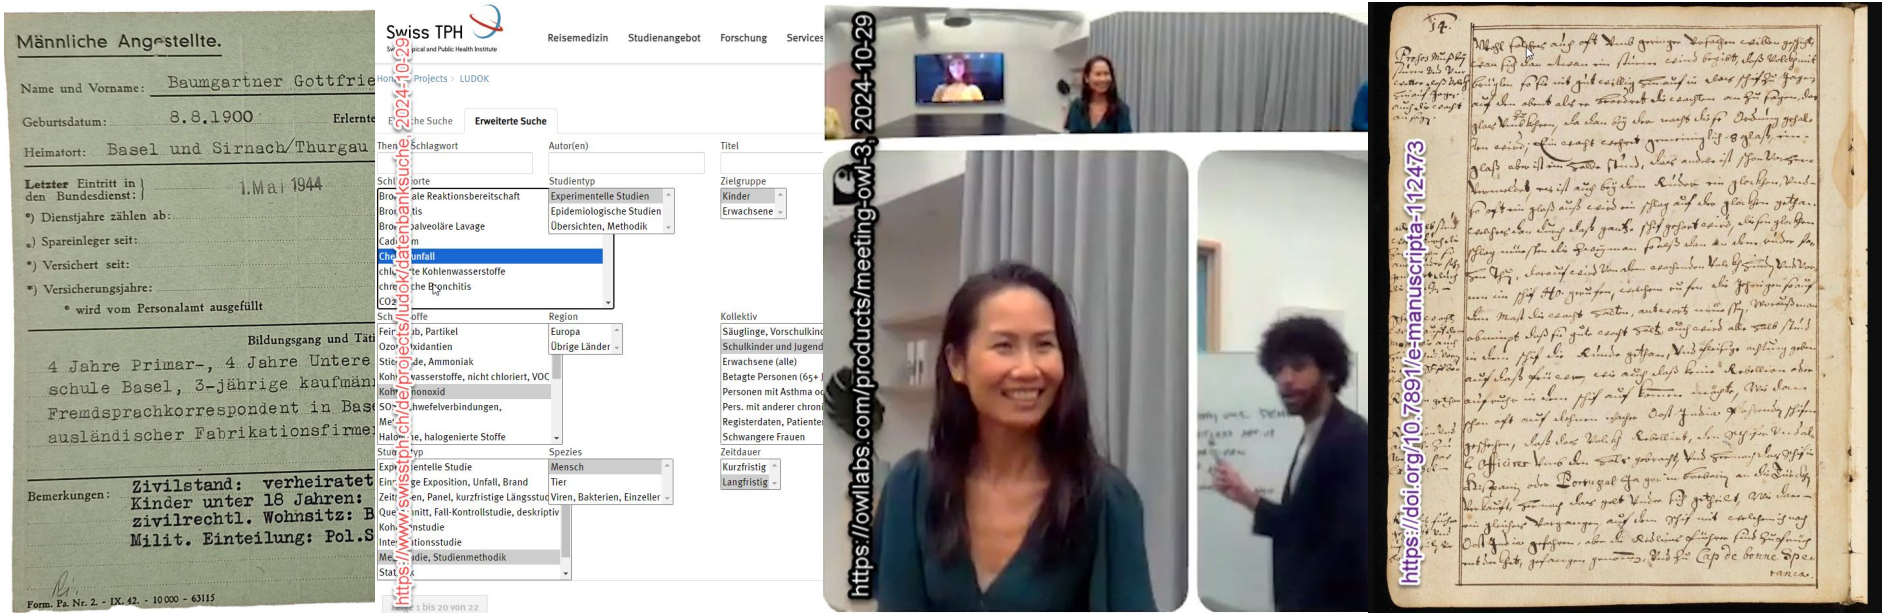

maximilian.hindermann@unibas.ch

Warum Benchmarking?

Epistemischer Grund:

- Evidenzbasierte Entscheidungsfindung darüber, welche(s) Modell(e) für welche Aufgabe(n) in einem Forschungsprojekt eingesetzt werden sollen.

Praktische Gründe. Zwingt Forschungsprojekte:

- Aufgaben zu operationalisieren
- Festzulegen, was “gut genug” ist
- Fertigkeiten und Budget gemäss Umsetzbarkeit zu prüfen
- Rechtliche oder ethische Fragen zu klären

Was ist Benchmarking?

Ein Modell bzw. eine Menge von Modellen für eine Aufgabe bzw. eine Menge von Aufgaben anhand eines Goldstandards und einer Metrik pro Aufgabe einstufen oder bewerten.

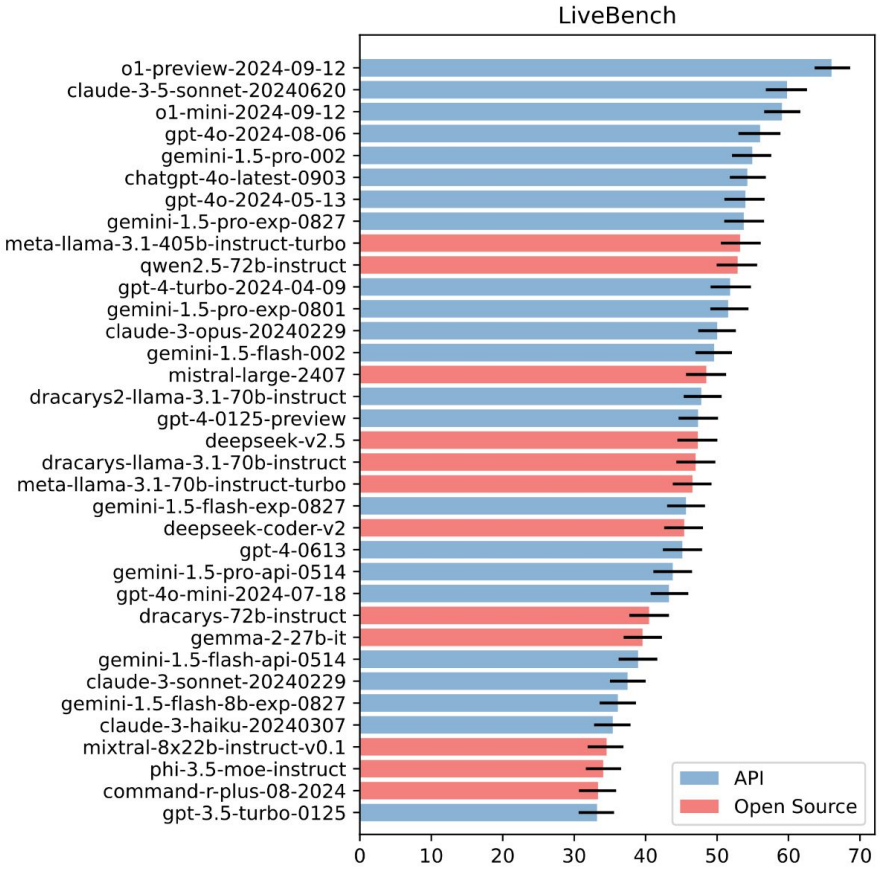

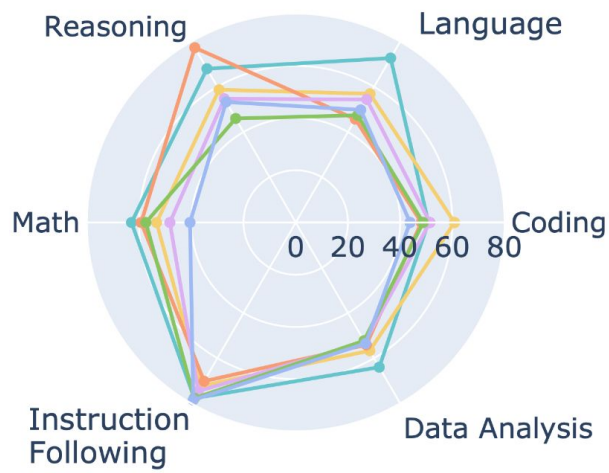

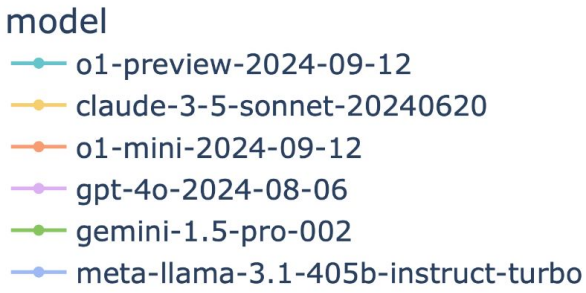

Colin White et al. (2024). LiveBench: A challenging, contamination-free LLM benchmark. arXiv preprint arXiv:2406.19314.

question_id string · *lengths* 64 100%	category string · *classes* reasoning 100%	ground_truth string · *lengths* 1 3 40.7%	turns sequence · *lengths* 1 100%	task string · *classes* spatial 33.3%
59979242f2437bc604ba87e9af3dd80878837a3ad01436d110fca1191f1dc0bb	reasoning	3	["Suppose I have a physical, solid, equilateral triangle, and I make two cuts. The two cuts are from two parallel lines, and both cuts pass through the interior of the triangle. How many pieces are there after the cuts? Think step by step, and then put your answer in **bold** as a single integer (for example, **0**). If you don't know, guess."]	spatial
95ef46b58759a1595006301bebb7be5edff15ad5fcaec453d3483c6d8d554b10	reasoning	2	["Suppose I have a physical, solid,…	spatial
efb9d081389f7fe028eb9a801d6751ab5cc6a2f4d09e21e1ca6c893e9b8f2fc5	reasoning	1	["Suppose I have a physical, solid,…	spatial
3d118e7c265b1ddf3c22d8765dc0c224dec03fad27d51c9687b46d61b6c4d0e5	reasoning	4	["Suppose I have a physical, solid square wit…	spatial

https://huggingface.co/datasets/livebench/reasoning, 2024-10-28

question_id string · lengths 64 100%	answer_id string · lengths 22 100%	model_id string · classes o1-mini-20… 1.1%	choices list · lengths 1 100%
59979242f2437bc604ba87e9af3dd80878837a3ad01436d110fca1191f1dc0bb	NvEWL5ecvoYrKM64PT9bb8	Phi-3-small-8k-instruct	[{ "index": 0, "turns": ["**4**"] }]
59979242f2437bc604ba87e9af3dd80878837a3ad01436d110fca1191f1dc0bb	7iFSHBmedsNoVBmLNjQqW6	Qwen1.5-4B-Chat	[{ "index": 0, "turns": ["There will be 3 pieces after the cuts."] }]
59979242f2437bc604ba87e9af3dd80878837a3ad01436d110fca1191f1dc0bb	PRhP3nkqS3a2rMSWt8nDeQ	o1-mini-2024-09-12	[{ "index": 0, "turns": ["**3**"] }]
59979242f2437bc604ba87e9af3dd80878837a3ad01436d110fca1191f1dc0bb	DP2nByzvdSXRBdG9ZUk3Wg	Qwen2-1.5B-Instruct	[{ "index": 0, "turns": ["There are 4 pieces."] }]
59979242f2437bc604ba87e9af3dd80878837a3ad01436d110fca1191f1dc0bb	c44auEizcaZzR466m2AiXH	Qwen1.5-0.5B-Chat	[{ "index": 0, "turns": ["The number of pieces that will be created is 2^3 = 8."…
59979242f2437bc604ba87e9af3dd80878837a3ad01436d110fca1191f1dc0bb	c9NdbqeA8Unj8rFSycLHez	Qwen2-0.5B-Instruct	[{ "index": 0, "turns": ["The number of pieces is 3."] }]
59979242f2437bc604ba87e9af3dd80878837a3ad01436d110fca1191f1dc0bb	6VNYfpPvXUrnKk6KDQao2b	gpt-3.5-turbo-1106	[{ "index": 0, "turns": ["Sure, let's think through this step by step. \n\nWhe…
59979242f2437bc604ba87e9af3dd80878837a3ad01436d110fca1191f1dc0bb	Nfwp5caHCxEPBygxTpDf4c	gpt-4-0613	[{ "index": 0, "turns": ["If you make two cuts through the interior of the…

https://huggingface.co/datasets/livebench/model_answer, 2024-10-28

Problemstellung

- Viele Beratungsanfragen mit ähnlichen Desiderata bezüglich LLMs:
  - Segmentierung und Transkription
  - (Meta)datenextraktion
- Viele gute Benchmarks, aber: nicht spezifisch genug für vorliegendes geisteswissenschaftliches Material
- Grosser Aufwand, Projekte isoliert zu beraten resp. zu benchmarken (verteiltes Wissen und verteilte Infrastruktur)

Lösung

- Einzelne Benchmarks standardisieren und zusammenführen: Vergleichbar, reproduzierbar, erweiterbar
- Gemeinsame Infrastruktur statt Einzelfalllösungen
- Benchmarking als fester Bestandteil der Projektberatung
- Forschungsprojekte befähigen, eigene Benchmarks umzusetzen

RISE Humanities Data Benchmark

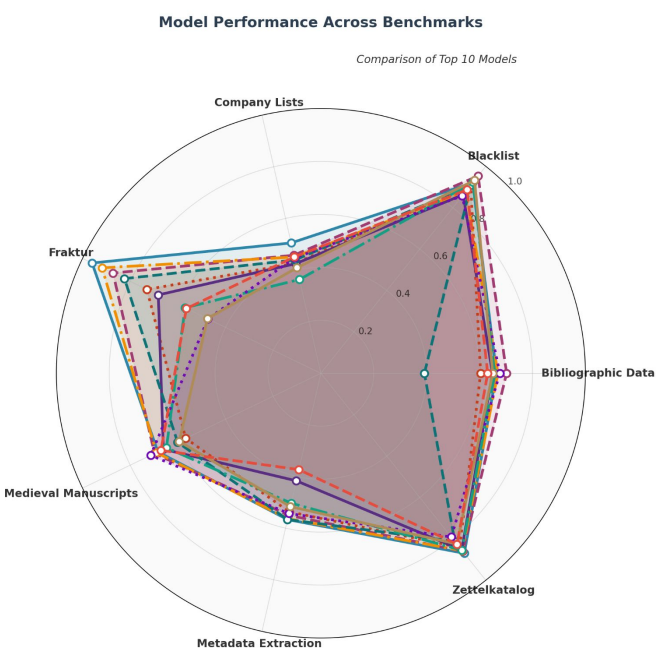

Generated: 2025-10-29 21:16:50 UTC

gemini-2.5-flash-preview-09-2025	Google	T0219	2025-10-01	prompt.txt	None	fuzzy 0.702	$0.0307	$0.0437	116.65	166.10
gpt-5	OpenAI	T0129	2025-10-01	prompt.txt	None	fuzzy 0.685	$0.3421	$0.4992	591.90	863.65
gpt-5-mini	OpenAI	T0130	2025-10-01	prompt.txt	None	fuzzy 0.677	$0.0582	$0.0860	411.12	607.56
gemini-2.5-flash	Google	T0105	2025-09-30	prompt.txt	None	fuzzy 0.669	$0.0252	$0.0376	195.82	292.59
claude-sonnet-4-20250514	Anthropic	T0107	2025-09-30	prompt.txt	None	fuzzy 0.669	$0.1692	$0.2531	127.79	191.16
o3	OpenAI	T0133	2025-10-01	prompt.txt	None	fuzzy 0.667	$0.1885	$0.2827	391.04	586.48
gemini-2.5-pro	Google	T0128	2025-09-30	prompt.txt	None	fuzzy 0.664	$0.1032	$0.1554	227.18	342.25
mistral-medium-2505	Mistral AI	T0170	2025-10-01	prompt.txt	None	fuzzy 0.661	$0.0222	$0.0336	128.32	194.01
gpt-4.1	OpenAI	T0139	2025-10-01	prompt.txt	None	fuzzy 0.657	$0.0952	$0.1449	298.94	455.07
qwen/qwen3-vl-8b-thinking	Alibaba (via OpenRouter)	T0233	2025-10-17	prompt.txt	None	fuzzy 0.657	$0.1268	$0.1931	923.12	1405.84
mistral-medium-2508	Mistral AI	T0169	2025-10-01	prompt.txt	None	fuzzy 0.654	$0.0220	$0.0336	112.70	172.31
claude-3-5-sonnet-20241022	Anthropic	T0009	2025-09-30	prompt.txt	None	fuzzy 0.653	$0.1682	$0.2576	124.19	190.17
gpt-4o	OpenAI	T0007	2025-09-30	prompt.txt	None	fuzzy 0.650	$0.1136	$0.1748	350.22	538.95
claude-3-7-sonnet-20250219	Anthropic	T0031	2025-09-30	prompt.txt	None	fuzzy 0.649	$0.1765	$0.2720	136.48	210.38
gpt-4.1-mini	OpenAI	T0140	2025-10-01	prompt.txt	None	fuzzy 0.648	$0.0199	$0.0307	164.93	254.41
mistral-large-latest	Mistral AI	T0187	2025-10-01	prompt.txt	None	fuzzy 0.639	$0.0805	$0.1259	136.28	213.12
claude-opus-4-1-20250805	Anthropic	T0127	2025-09-30	prompt.txt	None	fuzzy 0.631	$0.9735	$1.5435	203.32	322.38
meta-llama/llama-4-maverick	Meta (via OpenRouter)	T0234	2025-10-17	prompt.txt	None	fuzzy 0.626	$0.0062	$0.0099	151.02	241.35
gemini-2.0-flash	Google	T0008	2025-09-30	prompt.txt	None	fuzzy 0.604	$0.0052	$0.0087	69.66	115.32
gpt-5-nano	OpenAI	T0131	2025-10-01	prompt.txt	None	fuzzy 0.590	$0.0281	$0.0476	401.62	681.07
claude-opus-4-20250514	Anthropic	T0106	2025-09-30	prompt.txt	None	fuzzy 0.583	$0.8992	$1.5413	193.49	331.67
gemini-2.5-flash-lite-preview-09-2025	Google	T0211	2025-10-01	prompt.txt	None	fuzzy 0.579	$0.0048	$0.0083	18.69	32.28
gemini-2.5-flash-lite	Google	T0203	2025-10-01	prompt.txt	None	fuzzy 0.545	$0.0039	$0.0072	19.33	35.50

Hindermann, M., Marti, S., Alberto, A., Burkhardt, S., Decker, E., Frick, P., Kasper, L., Losada Palenzuela, J. L., Müller, G., Serif, I., & Spadini, E. (2025). RISE-UNIBAS/humanities_data_benchmark (v0.3.1). Zenodo. https://doi.org/10.5281/zenodo.17475190

RISE HDB: Factsheet

- Modulare Benchmarks (7 live und 10+ in Vorbereitung)
- Monatliche Testläufe (400+ Tests mit jeweils mind. 1 Lauf)
- Bewertung pro Benchmark pro Modell inkl. Kosten und Zeit
- Normalisierte Bewertung zwischen Benchmarks inkl. Kosten und Zeit
- Spezialisiert auf structured outputs von kommerziellen multimodalen LLMs
- Preisbeobachtung mittels Wayback Machine Snapshots
- API agnostisch (mittels https://pypi.org/project/generic-llm-api-client/)
- FAIRe Software und Daten (Benchmarks und Resultate)
- Automatisch bespieltes Frontend zur einfacheren Sichtung

RISE HDB Live Demo: Neuen Benchmark erstellen

- Ordner in `benchmarks` befüllen:

```
benchmarks/<benchmark_name>/
├── README.md              (use README_TEMPLATE.md)
├── images/                (image files: jpg, png)
├── prompts/               (text files with prompts)
├── ground_truths/         (json or txt files)
├── benchmark.py           (custom scoring)
└── dataclass.py           (optional: Pydantic models for structured output)
```

- Eintrag (“Test”) für jede gewünschte Konfiguration in `benchmark_tests.csv`.

RISE HDB Live Demo: aktuelles Frontend (v0.3.1)

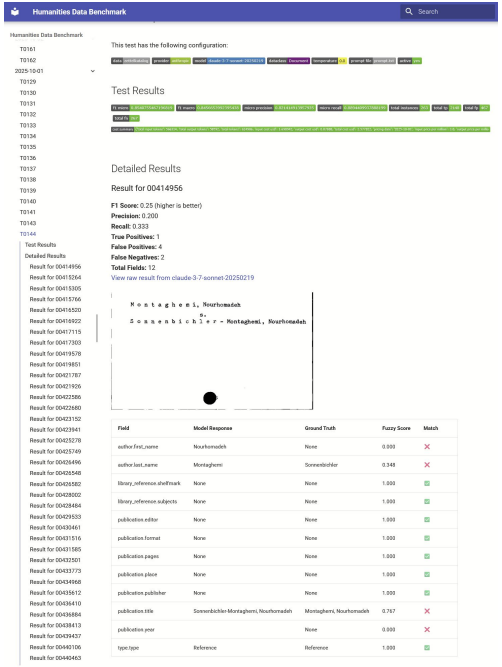

- https://rise-unibas.github.io/humanities_data_benchmark/
- GitHub Pages Instanz
- Seitenrenderings pro Benchmark
- Keine Datenbank

RISE HDB Live Demo: neues Frontend (geplant v0.4.0)

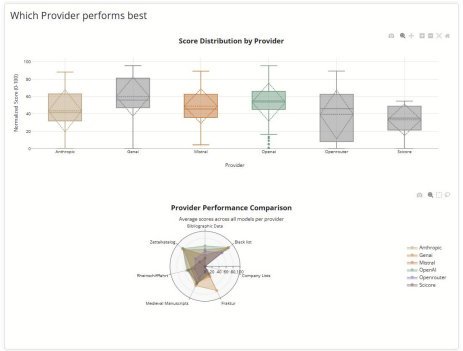

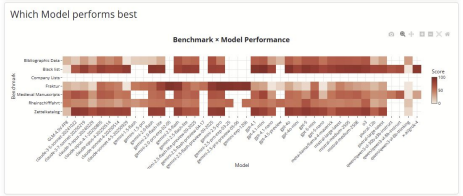

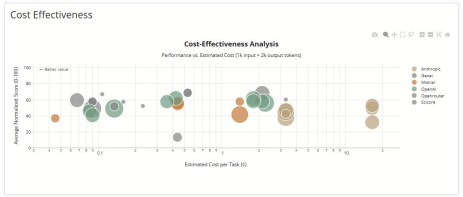

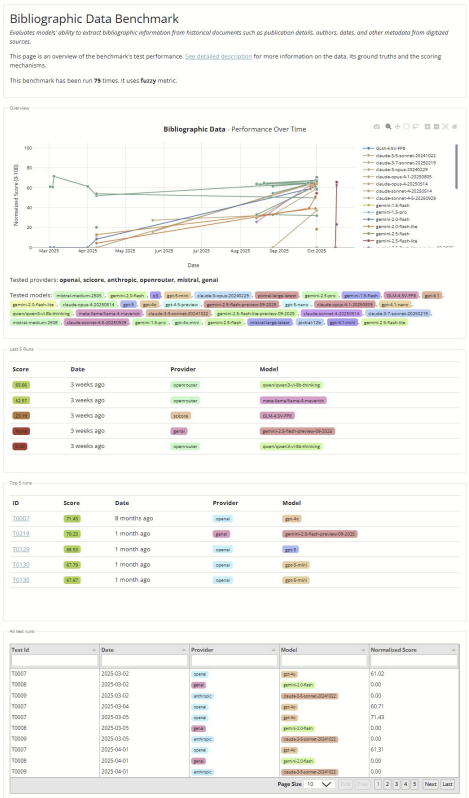

- Django-App basierend auf [NDR-Core]
- MongoDB
- Umfangreiche Suchen
- Datenvisualisierung mit Plotly

Herausforderungen

- Hoher Aufwand bei Ground Truth Erstellung wird systematisch unterschätzt
- Weiterverarbeitung generierter Daten oft unklar
- Hohe interpretative Dichte

- Feld extrem dynamisch
- Kosten

✓ Pilotprojekte mit echten Daten

✓ MosAIc, Nodegoat, etc.

✓ Trennung von Interpretation und Messung
✓ Mut zur Lücke
✓ EDA, Beratungshonorare, Dritt- und Zweitmittel

Learnings

- Benchmarking als epistemische Praxis:
  - Explizite Interpretationsentscheidungen
  - Projektspezifische Erfolgskriterien
  - Transparente Methodendokumentation
  - Fokus auf operationalisierbare Komponenten
- Modelle unterscheiden sich deutlich in Leistung, Kosten und Robustheit je nach Aufgabe.

Ausblick

- Finanzierung absichern
- Governance Onboarding externer Benchmarks
- Erweiterung auf
  - neue Datentypen (besonders Text)
  - neue Klassen von Aufgaben (besonders Anreicherung)
  - spezialisierte Modelle (besonders ATR)
- Bessere Integration mit sciCORE (HPC Universität Basel)
- Langzeitbeobachtung von Modellleistung

RISE HDB: Mitwirkende

Gabriel Müller
Domain Expert, Data Curator, Annotator

Sven Burkhardt
Annotator

Maximilian Hindermann
Data Curator, Annotator, Analyst, Engineer

Pema Frick
Domain Expert, Data Curator, Annotator, Analyst, Engineer

Anthea Alberto
Data Curator, Annotator

Elena Spadini
Data Curator, Annotator

Sorin Marti
Data Curator, Annotator, Analyst, Engineer

Ina Serif
Domain Expert, Data Curator, Annotator

Lea Kasper
Domain Expert, Data Curator, Annotator, Analyst, Engineer

Eric Decker
Data Curator, Annotator

José Luis Losada Palenzuela
Data Curator, Annotator

Mitmachen & Kontakt

RISE Humanities Data Benchmark

https://github.com/RISE-UNIBAS/humanities_data_benchmark
https://doi.org/10.5281/zenodo.16941752

Entwicklerteam

Maximilian Hindermann
maximilian.hindermann@unibas.ch
https://orcid.org/0000-0002-9337-4655

Sorin Marti
sorin.marti@unibas.ch
https://orcid.org/0000-0002-9541-1202

RISE

https://rise.unibas.ch
https://github.com/RISE-UNIBAS/

Fragen und Diskussion