

# FAIR Use of GPT-Generated Data in SSH Research: A Practical Guide

Dr. Maximilian Hindermann (RISE & UB Basel), 21.08.2024

Männliche Angestellte.		Dienststelle:	EIDGENÖSSISCHES JUSTIZ- UND POLIZEIDEPARTAMENT POLIZEIASTSTÜLLUNG ZENTRALLEITUNG DER ARBEITSLAGER ZHACH 2, Beimeggistrasse 11
Name und Vorname: Baumgartner Gottfried		9	9
Geburtsdatum: 8.8.1900		10	10
Erlernter Beruf: Kaufmann		11	11
Muttersprache: Deutsch		12	12
Heimatort: Basel und Sigriswil/Thurgau		13	13
Militärischer Grad: Soldat		14	14
Letzter Eintritt in den Bundesdienst: 1. Mai 1944		15	15
Frühere Tätigkeit im Bundesdienst: Dienststelle vom bis		16	16
*) Dienstjahre zählen ab: *) Spareinleger seit: *) Versichert seit: *) Versicherungsjahre: * wird vom Personalamt ausgefüllt		17	17
Unterbrechungen des Dienstverhältnisses:		18	18
Bildungsgang und Tätigkeit vor dem Eintritt in den Bundesdienst: 4 Jahre Primar-, 4 Jahre Untere Realschule, 2 Jahre Kantonale Handels- schule Basel, 3-jährige kaufmännische Lehre, 7 Jahre Angestellter und Fremdsprachkorrespondent in Basel und in Italien, seit März 1927 Vertreter ausländischer Fabrikationsfirmen.		19	19
Bemerkungen: Zivilstand: verheiratet Kinder unter 18 Jahren: -- zivilrechtl. Wohnsitz: Basel Milit. Einteilung: Pol.Sdt.HD		20	20
Austritt 31.12.45		21	21

```

"content": {
  "Bild1": {
    "Dateiname": "20230927_114325.jpg",
    "Name und Vorname": "Baumgartner Gottfried",
    "Geburtsdatum": "1900-08-08",
    "Heimatort": "Basel und Sigriswil/Thurgau",
    "Erlernter Beruf": "Kaufmann",
    "Muttersprache": "Deutsch",
    "Militärischer Grad": "Soldat",
    "Letzter Eintritt in den Bundesdienst": "1944-05-01",
    "Frühere Tätigkeit im Bundesdienst": "",
    "Bildungsgang und Tätigkeit vor dem Eintritt in den Bundesdienst": "Primar-, 4 Jahre Untere Realschule, 2 Jahre Kantonale Handels-  
schule Basel, 3-jährige kaufmännische Lehre, 7 Jahre Angestellter und  
Fremdsprachenkorrespondent in Basel und in Italien, seit Mi-  
Vertreter ausländischer Fabrikationsfirmen.",
    "Bemerkungen": "Zivilstand: verheiratet\nKinder unter 18 Jahr-  
-\\nzivilrechtl. Wohnsitz: Basel\nMilit. Einteilung: Pol.Sdt.  
31.12.45"
  }
},
  
```

# Who is Research and Infrastructure Support (RISE)?



“We support researchers in the humanities and social sciences at the University of Basel in the conception of computer-based research, the creation, analysis and user-oriented presentation of digital data, as well as in sustainable and open methods of data dissemination.”

# Overview

How to make GPT-generated data FAIR in the SSH?

1. What's FAIR data?
2. What's GPT-generated data, exactly?
3. Is this kind of data any different from the kind of data we already know?

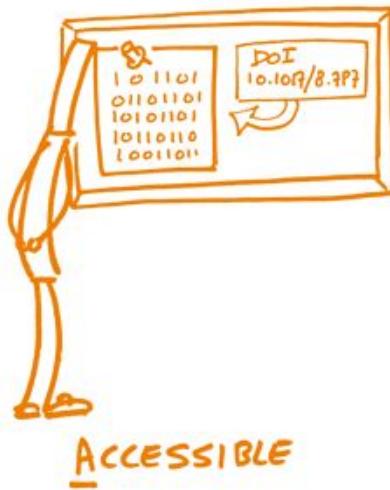
# FAIR data

## FAIR DATA PRINCIPLES

AH!



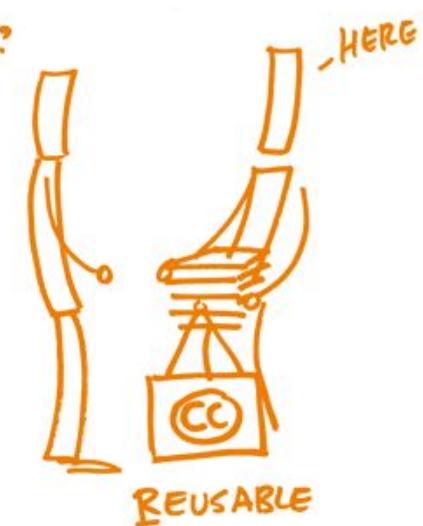
FINDABLE



ACCESSIBLE



INTEROPERABLE



REUSABLE HERE

Image credit: University Library Zurich, <https://www.ub.uzh.ch/en/wissenschaftlich-arbeiten/mit-daten-arbeiten/FAIR-und-Open-Data.html>

# Examples of GPT-generated data in SSH

- Extracted structured information from images (e.g., digitized historical sources, social media) or texts (e.g., research articles, transcriptions of historical sources)
- Unstructured information such as summaries (e.g., of research articles, historical sources)
- Queries (e.g., for data retrieval from an SQL database), scripts or code snippets

# Specific example: Extracting structured information from images using a multimodal LLM such as ChatGPT-4o

- Dissertation project by Tabea Wullschleger (University of Basel)
- Leadership staff in Swiss camps and homes for refugees from 1940 to 1949
- More than 1100 persons identified, source material contains around 4000 digitized personnel cards
- Information extraction from personnel cards with ChatGPT-4o via OpenAI-API
- Advantages over “classical” approach with Transkribus field models (not to mention manual extraction): cheaper, better, faster (, stronger) 

# Männliche Angestellte.

Dienststelle:

EIDGENÖSSISCHES JUSTIZ- UND POLIZEIBEAMTEMENT  
POLIZEIABTEILUNG  
ZENTRALLEITUNG DER ARBEITSLÄGER  
ZÜRICH 2, Beethovenstrasse 11  
PA

Name und Vorname: Baumgartner Gottfried

Geburtsdatum: 8.8.1900 Erlernter Beruf: Kaufmann Muttersprache: Deutsch

Heimatort: Basel und Sirmach/Thurgau Militärischer Grad: Soldat

Letzter Eintritt in den Bundesdienst:	1. Mai 1944	Frühere Tätigkeit im Bundesdienste:
*) Dienstjahre zählen ab:		Dienststelle vom bis
*) Spareinleger seit:		
*) Versichert seit:		
*) Versicherungsjahre: * wird vom Personalamt ausgefüllt		* Unterbrechungen des Dienstverhältnisses:

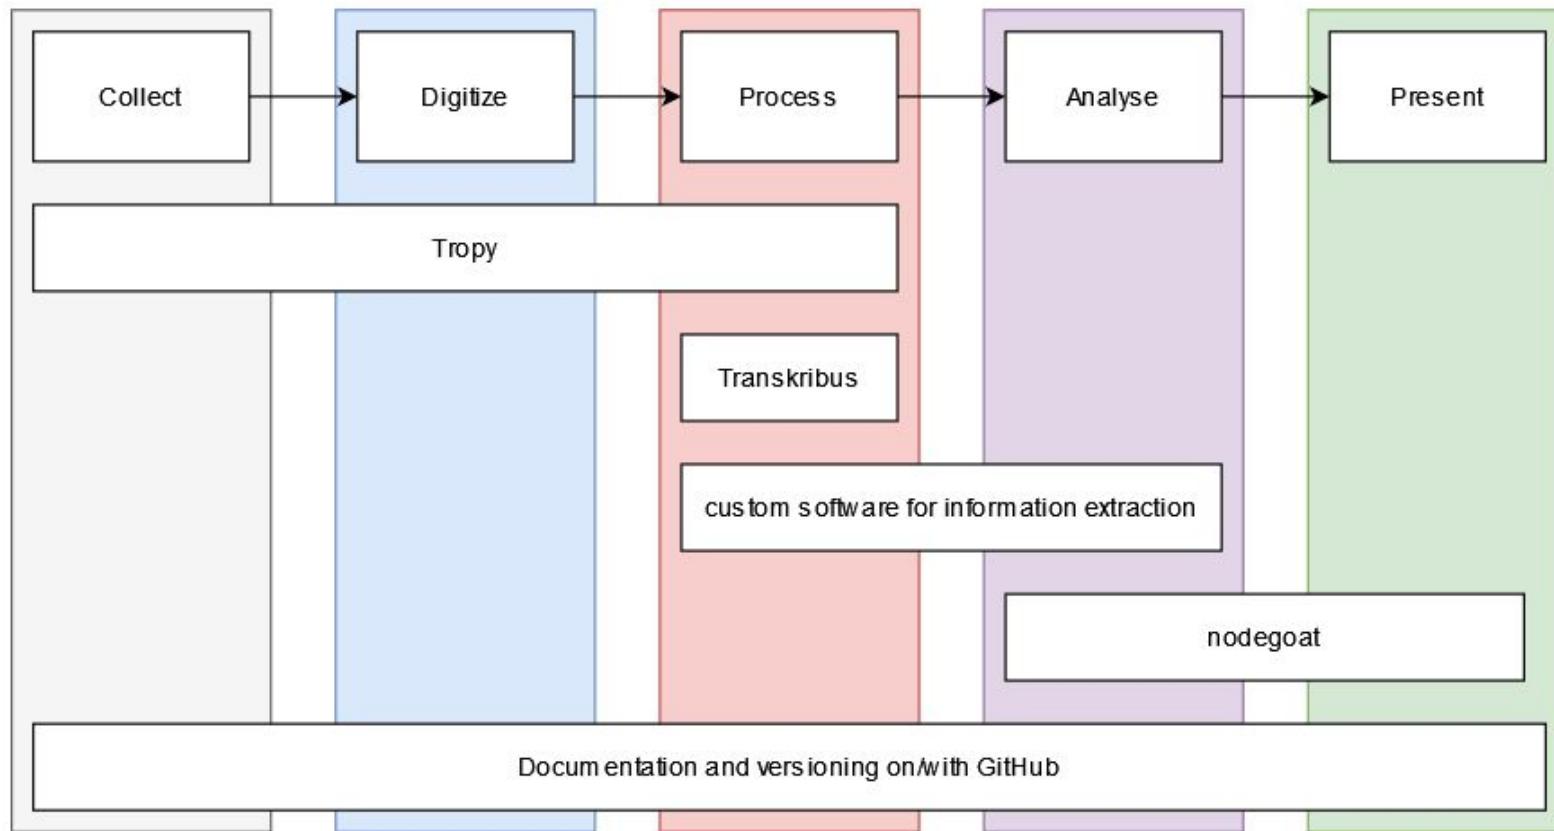
## Bildungsgang und Tätigkeit vor dem Eintritt in den Bundesdienst:

4 Jahre Primar-, 4 Jahre Untere Realschule, 2 Jahre Kantonale Handels-  
schule Basel, 3-jährige kaufmännische Lehre, 7 Jahre Angestellter und  
Fremdsprachkorrespondent in Basel und in Italien, seit März 1927 Vertreter  
ausländischer Fabrikationsfirmen.

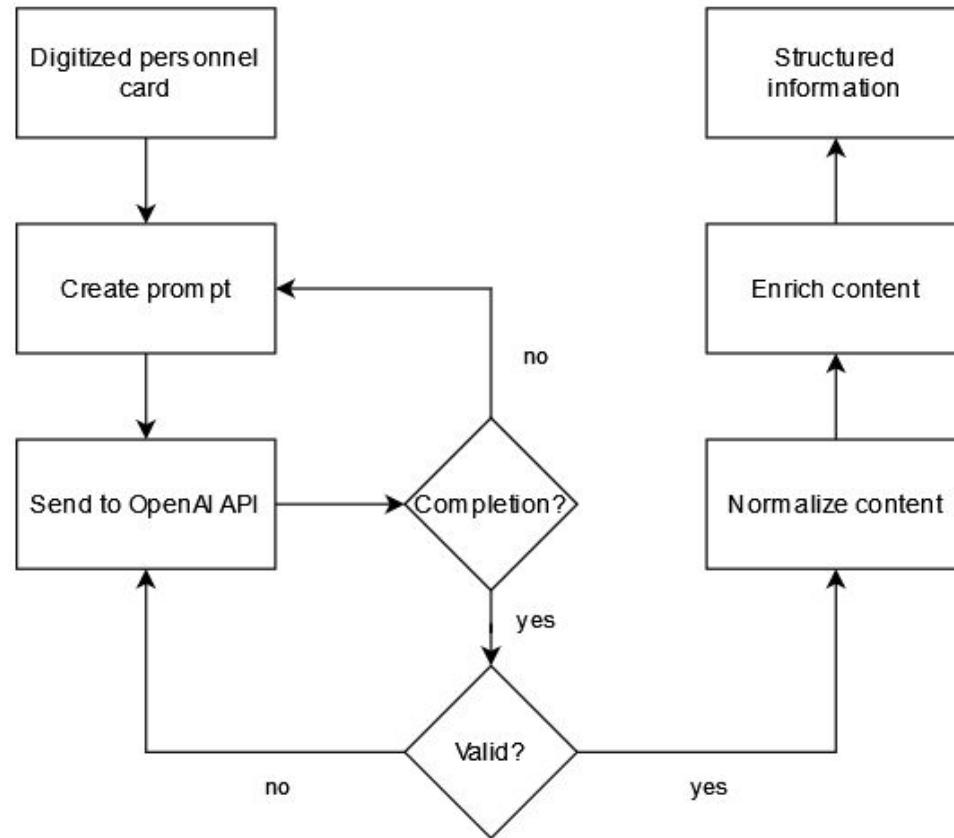
Bemerkungen: Zivilstand: verheiratet  
Kinder unter 18 Jahren: --  
zivilrechtl. Wohnsitz: Basel Austritt 31.12.45  
Milit. Einteilung: Pol.Sdt.HD

Dienstliche Stellung	Dienstort	Gehaltsklasse	Jahresgehalt Monatsgehalt Taglohn	Zeitpunkt der Gehaltsänderung			Bemerkungen, Akten etc.
				Tag	Monat	Jahr	
Hilfaleiter			3320.--	1.	Mai	1944	
"			4.630.—	1.	Januar	1945.	+ Zulagen

# Idealized data processing pipeline



# Information extraction workflow



# Prompt

Encoded images plus the following text:

"Please provide the information from the images as completely as possible in a JSON file with the structure Image1, Image2. All date entries should be in ISO format (YYYY-MM-DD). Do not use OCR. If the information is redundant, keep it anyway. The first image is named {path\_image1}. For the first image, use only the following fields: 'Dateiname', 'Name und Vorname', 'Geburtsdatum', 'Heimatort', 'Erlerner Beruf', 'Muttersprache', 'Militärischer Grad', 'Letzter Eintritt in den Bundesdienst', 'Frühere Tätigkeit im Bundesdienst', 'Bildungsgang und Tätigkeit vor dem Eintritt in den Bundesdienst', 'Bemerkungen'. The second image is named {path\_image2} and represents a table. For the second image, create an entry for each column containing only the following fields: 'Dateiname', 'Dienstliche Stellung', 'Dienstort', 'Gehaltsklasse', 'Jahresgehalt/Monatsgehalt/Taglohn', 'Zeitpunkt der Gehaltsänderung', 'Bemerkungen, Akten etc'."

# Completion

```
{"id": "chatcmpl-9TZVJXMRJj7GoQpdthNCs9lZloZ8o", "choices": [{"finish_reason": "stop", "index": 0, "logprobs": null, "message": {"content": "```json\n{\n  \"Bild1\": {\n    \"Dateiname\": \"20230927_114325.jpg\", \n    \"Name und Vorname\": \"Baumgartner Gottfried\", \n    \"Geburtsdatum\": \"1900-08-08\", \n    \"Heimatort\": \"Basel und Sirnach/Thurgau\", \n    \"Erlernter Beruf\": \"Kaufmann\", \n    \"Muttersprache\": \"Deutsch\", \n    \"Milit\u00e4rischer Grad\": \"Soldat\", \n    \"Letzter Eintritt in den Bundesdienst\": \"1944-05-01\", \n    \"Fr\u00fchere T\u00e4tigkeit im Bundesdienst\": \"\", \n    \"Bildungsgang und T\u00e4tigkeit vor dem Eintritt in den Bundesdienst\": \"4 Jahre Primar-, 4 Jahre Untere Realschule, 2 Jahre Kantonale Handelsschule Basel, 3-j\u00e4hrige kaufm\u00e4nnische Lehre, 7 Jahre Angestellter und Fremdsprachenkorrespondent in Basel und in Italien, seit M\u00e4rz 1927 Vertreter ausl\u00e4ndischer Fabrikationsfirmen.\", \n    \"Bemerkungen\": \"Zivilstand: verheiratet\\nKinder unter 18 Jahren: \\u2014\\nzivilrechtl. Wohnsitz: Basel\\nMilit. Einteilung: Pol.Sdt.HD\\nAustritt 31.12.45\\n\", \n    \"Bild2\": {\n      \"Eintrag1\": {\n        \"Dateiname\": \"20230927_114332.jpg\", \n        \"Dienstliche Stellung\": \"Hilfleiter\", \n        \"Dienstort\": \"\", \n        \"Gehaltsklasse\": \"\", \n        \"Jahresgehalt/Monatsgehalt/Taglohn\": \"3320.\\u2013\", \n        \"Zeitpunkt der Gehalts\u00e4nderung\": \"1944-05-01\", \n        \"Bemerkungen, Akten etc\": \"\\n\", \n        \"Eintrag2\": {\n          \"Dateiname\": \"20230927_114332.jpg\", \n          \"Dienstliche Stellung\": \"Hilfleiter\", \n          \"Dienstort\": \"\", \n          \"Gehaltsklasse\": \"\", \n          \"Jahresgehalt/Monatsgehalt/Taglohn\": \"4630.\\u2013\", \n          \"Zeitpunkt der Gehalts\u00e4nderung\": \"1945-01-01\", \n          \"Bemerkungen, Akten etc\": \"+ Zulagen\\n\", \n          \"role\": \"assistant\", \n          \"function_call\": null, \n          \"tool_calls\": null\n        }\n      }\n    }\n  }\n}\n```\n", "role": "assistant", "function_call": null, "tool_calls": null}]}], "created": 1716835017, "model": "gpt-4o-2024-05-13", "object": "chat.completion", "system_fingerprint": "fp_3196d36131", "usage": {"completion_tokens": 487, "prompt_tokens": 2469, "total_tokens": 2956}}
```

# Completion metadata

```
1  {
2      "id": "chatcmpl-9TWh0NzvhIiJmAOwWXMFQLWleFMBZ",
3      "choices": [
4          {
5              "finish_reason": "stop",
6              "index": 0,
7              "logprobs": null,
8              "message": {
9                  "content": "Hello, how can I assist you today?",
10                 "role": "assistant",
11                 "function_call": null,
12                 "tool_calls": null
13             }
14         }
15     ],
16     "created": 1716824210,
17     "model": "gpt-4o-2024-05-13",
18     "object": "chat.completion",
19     "system_fingerprint": "fp_927397958d",
20     "usage": {
21         "completion_tokens": 477,
22         "prompt_tokens": 2469,
23         "total_tokens": 2946
24     }
25 }
```

# Completion data

```
9 "content": {  
10   "Bild1": {  
11     "Dateiname": "20230927_114325.jpg",  
12     "Name und Vorname": "Baumgartner Gottfried",  
13     "Geburtsdatum": "1900-08-08",  
14     "Heimatort": "Basel und Sirnach/Thurgau",  
15     "Erlernter Beruf": "Kaufmann",  
16     "Muttersprache": "Deutsch",  
17     "Militärischer Grad": "Soldat",  
18     "Letzter Eintritt in den Bundesdienst": "1944-05-01",  
19     "Frühere Tätigkeit im Bundesdienst": "",  
20     "Bildungsgang und Tätigkeit vor dem Eintritt in den Bundesdienst": "4 Jahre  
Primar-, 4 Jahre Untere Realschule, 2 Jahre Kantonale Handelsschule Basel,  
3-jährige kaufmännische Lehre, 7 Jahre Angestellter und  
Fremdsprachenkorrespondent in Basel und in Italien, seit März 1927  
Vertreter ausländischer Fabrikationsfirmen.",  
21     "Bemerkungen": "Zivilstand: verheiratet\nKinder unter 18 Jahren:  
-\nzivilrechtl. Wohnsitz: Basel\nMilit. Einteilung: Pol.Sdt.HD\nAustritt  
31.12.45"  
22   },  
23   "Bild2": [  ]  
24 },  
25 }
```

# Conclusion

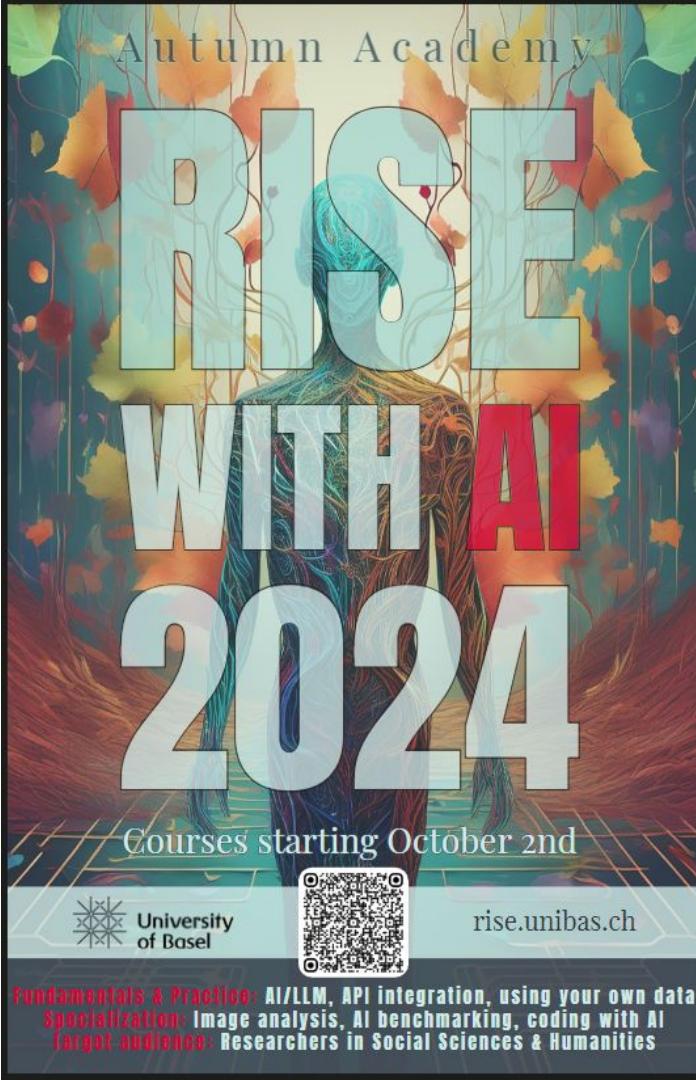
In order to be FAIR, GPT-generated data in SSH must

1. include prompt, completion content and completion metadata, and
2. make available the pipelines for data generation and processing as FAIR research software (in the sense of [Barker et al. 2022](#)).

Note that these are necessary and not sufficient conditions!

# What RISE is working on right now

- Benchmarking of LLM models
- Generic post processing infrastructure
- Packages for AI-wrappers and pipelines
- [Crash course series about AI in SSH](#)



Fundamentals & Practice: AI/LLM, API integration, using your own data  
Specialization: Image analysis, AI benchmarking, coding with AI  
Target audience: Researchers in Social Sciences & Humanities

# Q&A

Email: [maximilian.hindermann@unibas.ch](mailto:maximilian.hindermann@unibas.ch) or [rise@unibas.ch](mailto:rise@unibas.ch)

Web: <https://rise.unibas.ch/>

GitHub: <https://github.com/RISE-UNIBAS>