

# OCR of Legacy Documents

as a Building Block in Industrial Disaster Prevention

Isemann, D., Niekler, A., Preßler, B., Viereck F. and Heyer G.



# Background

Project: “Knowledge Management for Legacy Documents in Science, Administration and Industry”

2

# The Asse Pit



3

# Asse History



- 1909-1964: Salt mine
- 1964-1978: “Exploratory final storage” (Versuchsendlager) for radioactive waste
- 1. 1. 1979: No new radioactive material accepted
- 1979—now: Managing and maintaining the site and its contents
- 1988: Ingress of water into the pit
- 2009: Change of management, political pressures

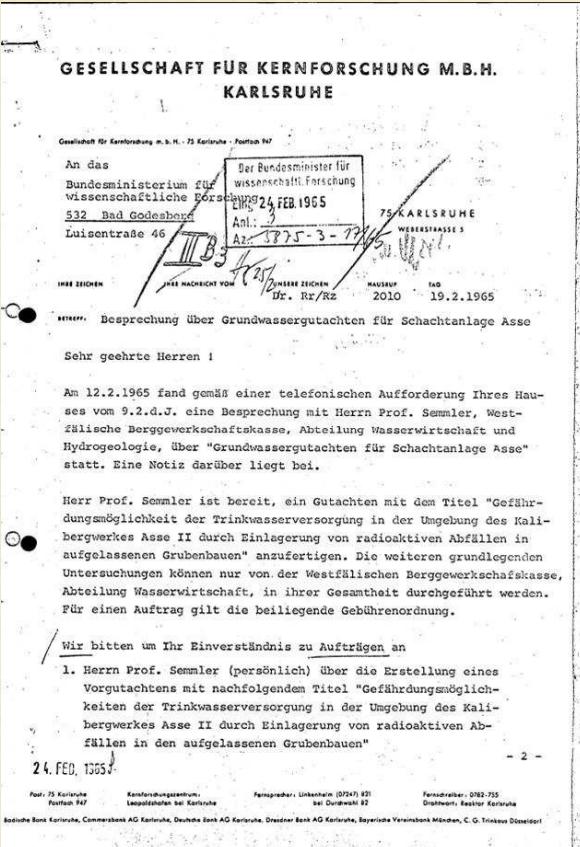
4

# Asse Legacy Files



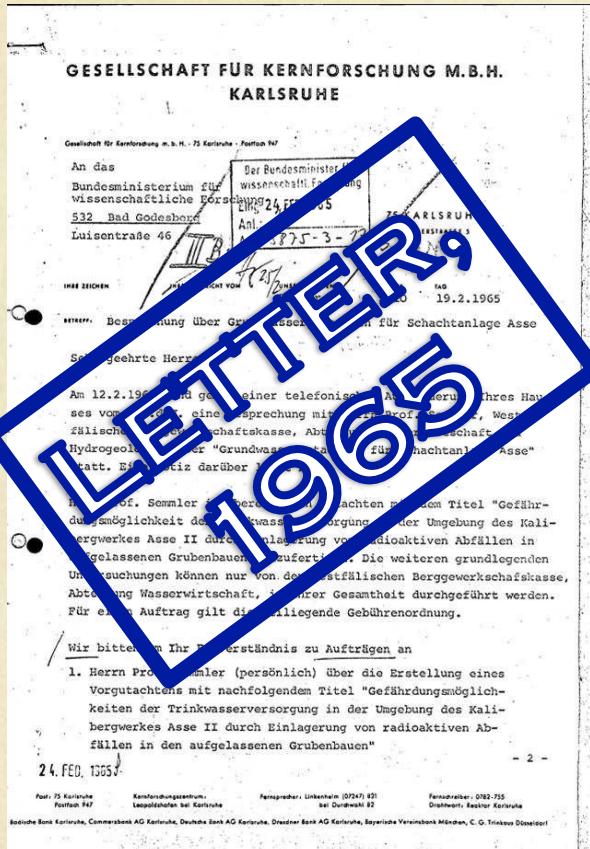
- In the order of 5000 file folders documenting / including (no claim to completeness):
  - Geological and mining surveys
  - Radioactive waste management and reactive transport studies
  - Scientific and administrative correspondence
  - Telephone protocols and meeting minutes
  - Delivery notes / receipts for radioactive substances
  - Reports / assessments of extraordinary events (e.g. earthquakes, operational incidents, etc.)
  - Guidelines and written exhortations making reference to legal and regulatory frameworks governing nuclear waste disposal
- Huge source of information of political, historical and practical interest (current plan is to empty out the nuclear waste repository)

# Example Documents



INHALTSVERZEICHNIS	
	Seite
I. EINFÜHRUNG . . . . .	1
II. ARBEITSMETHODIK . . . . .	3
III. GEOMORPHOLOGISCHE ÜBERSICHT . . . . .	4
IV. STRATIGRAPIE . . . . .	7
IV.1. Zechstein . . . . .	7
IV.2. Buntsandstein . . . . .	10
IV.3. Muschelkalk . . . . .	24
IV.4. Keuper . . . . .	38
IV.5. Lias und Dogger . . . . .	47
IV.6. Kreide (Unter-Hauterivium) . . . . .	50
IV.7. Tertiär (Unter-Oligozän) . . . . .	52
IV.8. Quartär . . . . .	60
V. TEKTONIK . . . . .	70
V.1. "Bereich des verstürtzen Deckgebirges" . . . . .	70
V.2. Der tektonische Bau des Salzgebirges . . . . .	72
V.2.1. Schacht Asse II . . . . .	73
V.2.2. Schacht Asse I . . . . .	79
V.3. Der tektonische Bau des Deckgebirges . . . . .	81
V.3.1. Art und Entstehung der tektonischen Formen . . . . .	81
V.3.1.1. Verwerfungen . . . . .	81
V.3.1.2. Klüftung . . . . .	86
V.3.1.3. Tangentiale Einengung ? . . . . .	88
V.3.2. Die räumliche Verteilung der tektonischen Formen und ihre Bedeutung für die Strukturbildung . . . . .	90
V.3.2.1. Der nordwestliche Strukturschlund und der Salzstock von Gr.Denke . . . . .	90
V.3.2.2. Die Asse i.e.S. . . . .	97
V.3.2.2.1. Der NW-Abschnitt der SW-Flanke . . . . .	97
V.3.2.2.2. Der SE-Abschnitt der SW-Flanke . . . . .	101
V.3.2.2.3. Der Mittelabschnitt der SW-Flanke . . . . .	103
V.3.2.3. Die südöstliche Verlängerung der Asse . . . . .	108
V.4. Der zeitliche Ablauf der Strukturbildung . . . . .	114
VI. ZUSAMMENFASSUNG . . . . .	118
VII. LITERATURVERZEICHNIS . . . . .	122
VIII. ANHANG	
geologische Profile	
Streichlinienkarte der SW-Flanke	
Karte der Quartärverbreitung und -mächtigkeit	
geologische Karte	

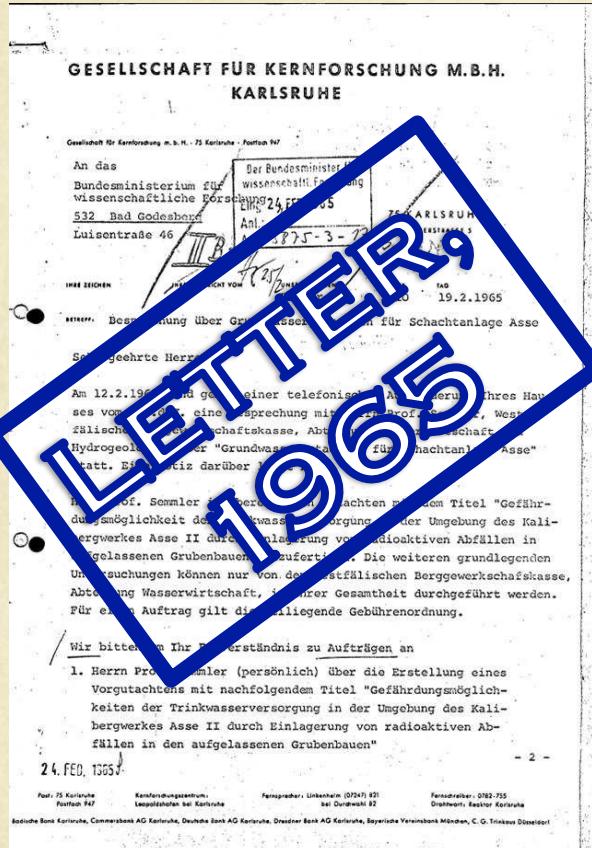
# Example Documents



## INHALTSVERZEICHNIS

	Seite	
I.	EINFÜHRUNG . . . . .	1
II.	ARBEITSMETHODIK . . . . .	3
III.	GEO MORPHOLOGISCHE ÜBERSICHT . . . . .	4
IV.	STRATIGRAPHIE . . . . .	7
IV.1.	Zechstein . . . . .	7
IV.2.	Buntsandstein . . . . .	10
IV.3.	Muschelkalk . . . . .	24
IV.4.	Keuper . . . . .	38
IV.5.	Lias und Dogger . . . . .	47
IV.6.	Mergelsteine (Unter-Hauterivium) . . . . .	50
IV.7.	Tertiär (Unter-Oligozän) . . . . .	52
IV.8.	Quarzit . . . . .	60
V.	TEKTONIK . . . . .	70
V.1.	"Bereich des verstürzten Deckgebirges" . . . . .	70
V.2.	Der tektonische Bau des Salzgebirges . . . . .	72
V.2.1.	Schacht Asse II . . . . .	73
V.2.2.	Schacht Asse I . . . . .	79
V.3.	Der tektonische Bau des Deckgebirges . . . . .	81
V.3.1.	Art und Entstehung der tektonischen Formen . . . . .	81
V.3.1.1.	Verwerfungen . . . . .	81
V.3.1.2.	Klüffungen . . . . .	86
V.3.1.3.	Tangentialne Einkerbung ? . . . . .	88
V.3.2.	Die räumliche Verteilung, der tektonischen Formen und ihre Bedeutung für die Strukturbildung . . . . .	90
V.3.2.1.	Der nordwestliche Strukturschlund und der Südlitzeknick . . . . .	90
V.3.2.2.	Die Asse, i.e.s. Dr. Benkert . . . . .	97
V.3.2.2.1.	Der NW-Abschnitt der SW-Flanke . . . . .	97
V.3.2.2.2.	Der SE-Abschnitt der SW-Flanke . . . . .	101
V.3.2.2.3.	Der Mittelabschnitt der SW-Flanke . . . . .	103
V.3.2.3.	Die südöstliche Verlängerung der Asse . . . . .	108
V.4.	Der zeitliche Ablauf der Strukturbildung . . . . .	114
VI.	ZUSAMMENFASSUNG . . . . .	118
VII.	LITERATURVERZEICHNIS . . . . .	122
VIII.	ANHANG	
	geologische Profile	
	Streichlinienkarte der SW-Flanke	
	Karte der Quartärverbreitung und -mächtigkeit	
	geologische Karte	

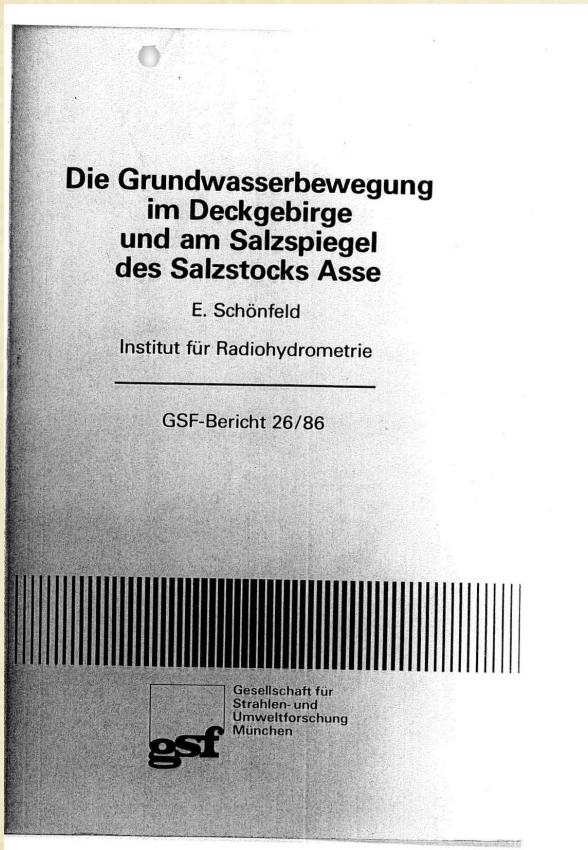
# Example Documents



INHALTSVERZEICHNIS

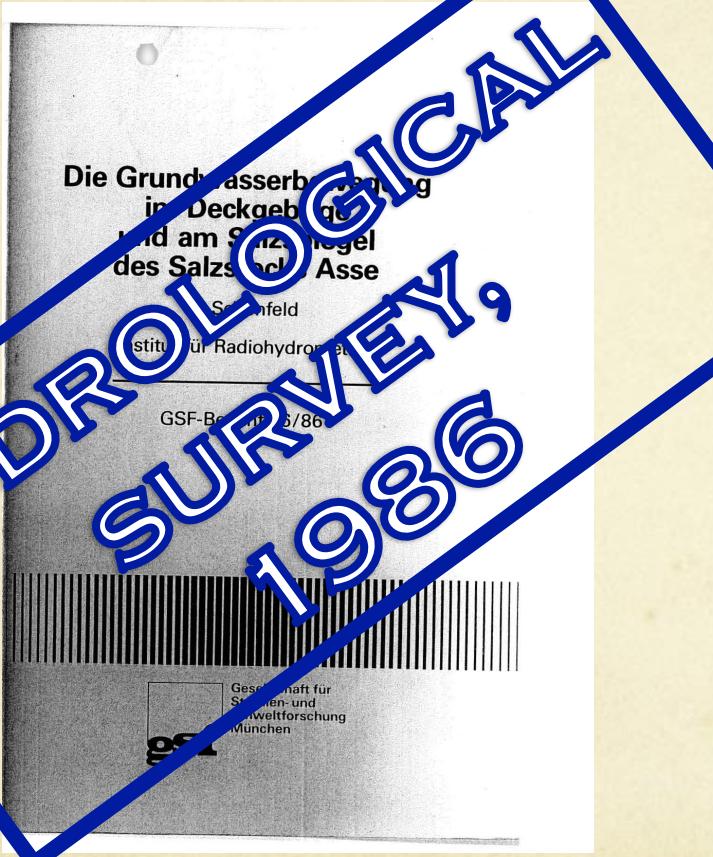
I.	EINFÜHRUNG . . . . .	1
II.	ARBEITSMETHODEN . . . . .	3
III.	GEOMORPHOLOGISCHE ÜBERSICHT . . . . .	4
IV.	STRATIGRAPHIE . . . . .	7
IV.1.	Zechstein . . . . .	7
IV.2.	Muschelkalk . . . . .	10
IV.3.	Kreide (Hauterivium) . . . . .	24
IV.4.	Lias und unteres Jura (Bajocium) . . . . .	38
IV.5.	Tert (Unter-Obereozän) . . . . .	47
IV.6.	Quarzit . . . . .	50
IV.7.	Metavulkanite . . . . .	52
IV.8.	Metamorphe Gesteine . . . . .	60
V.	Geotektonische Verstürtzungen des Zechsteins . . . . .	70
V.1.	Der geotektonische Bau des Zechsteins . . . . .	70
V.2.	Die geotektonischen Verstürtzungen des Zechsteins . . . . .	72
V.2.1.	Schicht Asse II . . . . .	73
V.2.2.	Die geotektonischen Verstürtzungen des Zechsteins . . . . .	81
V.3.	Die geotektonischen Verstürtzungen des Zechsteins . . . . .	81
V.3.1.	Art und Entstehungszeit der geotektonischen Verstürtzungen . . . . .	81
V.3.2.	Klüftung . . . . .	86
V.3.2.1.	Tangential Klüftung . . . . .	86
V.3.2.1.1.	Die räumliche Ausbreitung der tektonischen Formen und ihr Beitrag zur Entstehung für die geotektonischen Verstürtzungen . . . . .	90
V.3.2.1.2.	Die räumliche Struktur schluchtiger und unregelmäßiger Klüfte . . . . .	90
V.3.2.2.	Die i.I.S. . . . .	97
V.3.2.2.1.	Der Nordschnitt der SW-Verwerfung . . . . .	97
V.3.2.2.2.	Der SE-Schnitt der SW-Verwerfung . . . . .	107
V.3.2.2.3.	Mittelabschnitt der SW-Verwerfung . . . . .	108
V.3.2.2.4.	südöstliche Verlagerung der Asse . . . . .	108
V.3.2.2.5.	Die geotektonischen Verstürtzungen der Asse . . . . .	114
V.3.2.2.6.	Die geotektonischen Verstürtzungen der Asse . . . . .	114
V.3.2.2.7.	Die geotektonischen Verstürtzungen der Asse . . . . .	118
V.3.2.2.8.	LITERATURVERZEICHNIS . . . . .	122
ANHANG . . . . .		
geologische Karte . . . . .		
Streichlinienkarte der SW-Verwerfung . . . . .		
Karte der Quellenverbringung und . . . . .		
geologische Karte . . . . .		

# Example Documents



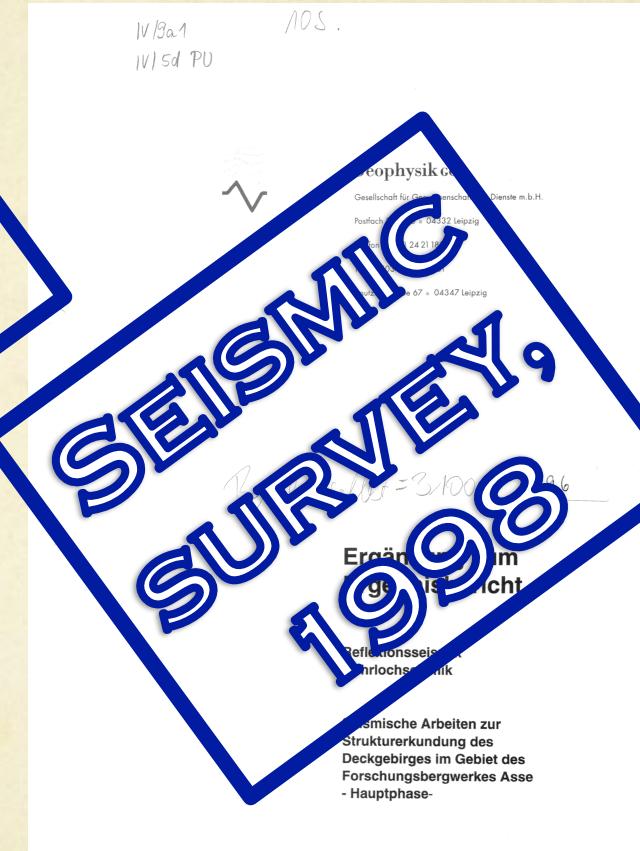
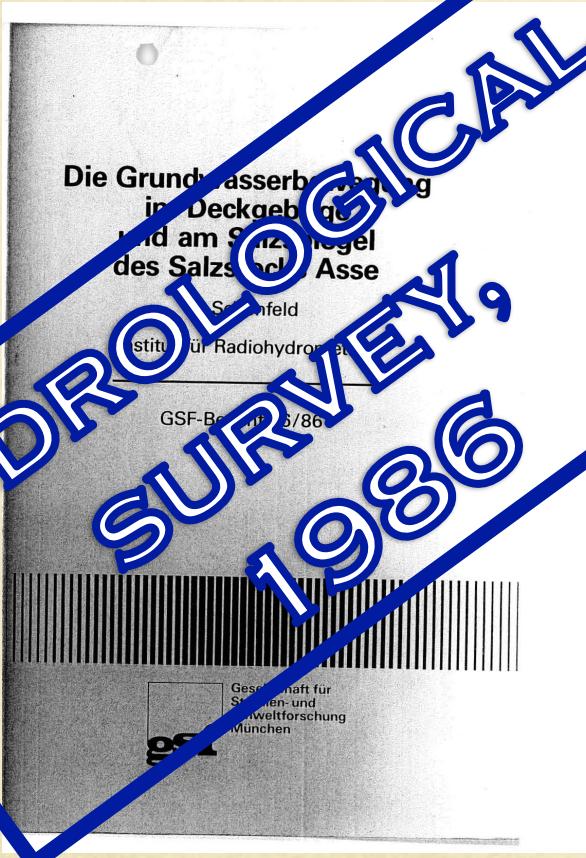
9

# Example Documents



10

# Example Documents



# Challenge for OCR



Herrn Professor ██████ wurde eine Übersicht über die geologischen  
ung bergmännischen Verhältnisse in der Schachtanlage Asse gegeben,  
und die geplanten Versuchsarbeiten zur Unterbringung von radio-  
aktiven Abfällen erläutert. Danach wurde anhand einer Karte  
1 : 25 000 die topographischen Situation erörtert. Zur Vermeidung

## Google Drive OCR

. | Herrn Professor XXXXX wurde eine: Übar:=icht über? du: genlug:.scfuan  
um; hergmännischen Uerhältnisse in der: Schachtanlage ,um:  
und die qaplanten versuchsarbaitan zu: Unterbringung man radia  
MEäILEn erläutert. Danach wurde anhand einer Harta  
1 : 25 üüü dia top-ugraphischen Eituatinn arä:terr:.. Zur vermeiflung

12

# Challenge for OCR



Herrn Professor █████ wurde eine Übersicht über die geologischen  
ung bergmännischen Verhältnisse in der Schachtanlage Asse gegeben,  
und die geplanten Versuchsarbeiten zur Unterbringung von radio-  
aktiven Abfällen erläutert. Danach wurde anhand einer Karte  
1 : 25 000 die topographischen Situation erörtert. Zur Vermeidung

Digitized by Google

## Google Drive OCR (correctly identified tokens)

. | Herrn Professor XXXXX wurde eine: Übar:=icht über? du: genlug:.scfuan  
um; hergmännischen Uerhältnisse in der: Schachtanlage ,um:  
und die qaplanten versuchsarbaitan zu: Unterbringung man radia  
MEäILEn erläutert. Danach wurde anhand einer Harta  
1:25 üüü dia top-ugraphischen Eituatinn arä:terr... Zur vermeiflung

13

# Challenge for OCR

Herrn Professor [REDACTED] wurde eine Übersicht über die geologischen  
ung bergmännischen Verhältnisse in der Schachtanlage Asse gegeben,  
und die geplanten Versuchsarbeiten zur Unterbringung von radio-  
aktiven Abfällen erläutert. Danach wurde anhand einer Karte  
1 : 25 000 die topographischen Situation erörtert. Zur Vermeidung

Google Drive OCR (correctly identified tokens)

Herrn Professor wurde in und die erläutert. Danach wurde anhand einer 1:25 Zur

14

# Challenge for OCR



Herrn Professor [REDACTED] wurde eine Übersicht über die geologischen  
ung bergmännischen Verhältnisse in der Schachtanlage Asse gegeben,  
und die geplanten Versuchsarbeiten zur Unterbringung von radio-  
aktiven Abfällen erläutert. Danach wurde anhand einer Karte  
1 : 25 000 die topographischen Situation erörtert. Zur Vermeidung

Digitized by Google

## Google Drive OCR (correctly identified tokens)

Herrn Professor wurde  
in  
und die  
erläutert. Danach wurde anhand einer  
1 : 25 Zur

15

# Challenge for OCR



Herrn Professor ██████ wurde eine Übersicht über die geologischen  
ung bergmännischen Verhältnisse in der Schachtanlage Asse gegeben,  
und die geplanten Versuchsarbeiten zur Unterbringung von radio-  
aktiven Abfällen erläutert. Danach wurde anhand einer Karte  
1 : 25 000 die topographischen Situation erörtert. Zur Vermeidung

## Online OCR service

Herrn Professor XXXXXX wurde ein\* übercicht über dio geologischen  
14.11/4.9111111

une bergmännischen Verhältnisse in der Schachtanlage Asse 9.agebenf  
und die geplanten Verauchsarbeiten zur Unterbrin9ung von radio-  
aktiven Abfällen erläutert. Danach wurde anhand einer Karte  
1 : 25 000 die topographischen Situation erörtert. Zur Vermeidung

16

# Challenge for OCR



Herrn Professor [REDACTED] wurde eine Übersicht über die geologischen  
ung bergmännischen Verhältnisse in der Schachtanlage Asse gegeben,  
und die geplanten Versuchsarbeiten zur Unterbringung von radio-  
aktiven Abfällen erläutert. Danach wurde anhand einer Karte  
1 : 25 000 die topographischen Situation erörtert. Zur Vermeidung

## Online OCR service (correctly identified tokens)

Herrn Professor wurde über geologischen  
bergmännischen Verhältnisse in der Schachtanlage Asse  
und die geplanten zur von radio-  
aktiven Abfällen erläutert. Danach wurde anhand einer Karte  
1 : 25 000 die topographischen Situation erörtert. Zur Vermeidung

# Challenge for OCR



Herrn Professor [REDACTED] wurde eine Übersicht über die geologischen  
ung bergmännischen Verhältnisse in der Schachtanlage Asse gegeben,  
und die geplanten Versuchsarbeiten zur Unterbringung von radio-  
aktiven Abfällen erläutert. Danach wurde anhand einer Karte  
1 : 25 000 die topographischen Situation erörtert. Zur Vermeidung

Better, but  
keywords  
are missing

## Online OCR service (correctly identified tokens)

Herrn Professor

wurde

über

geologischen

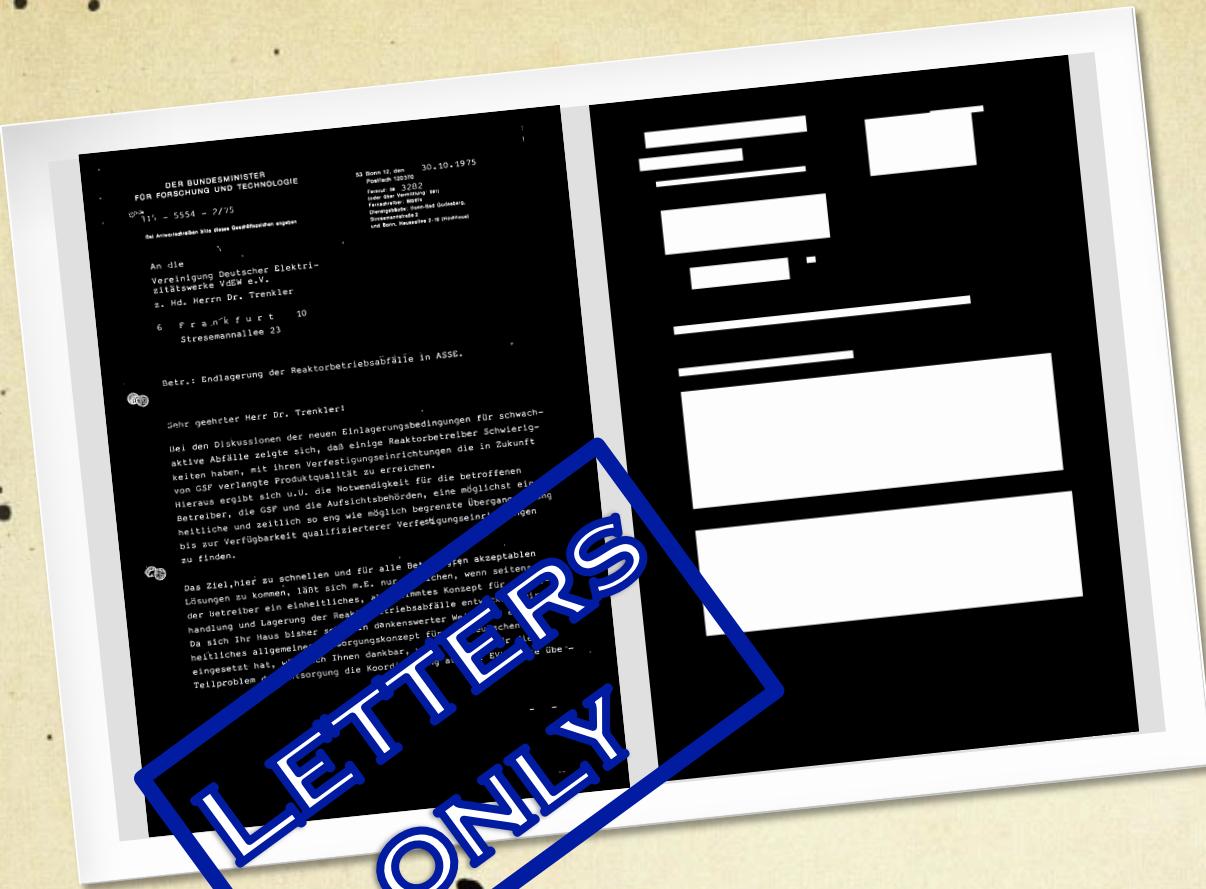
bergmännischen Verhältnisse in der Schachtanlage Asse  
und die geplanten [REDACTED] zu [REDACTED] von radio-  
aktiven Abfällen erläutert. Danach wurde anhand einer Karte  
1 : 25 000 die topographischen Situation erörtert. Zur Vermeidung



# Vision for the Project

- Archiving: Searchable access to legacy paper documents
- Repurposing: Extracting metadata, meaningful connections, ontology learning
- Integrated processing chain from OCR to semantics
- First exploratory study: Segmentation of letterheads

19

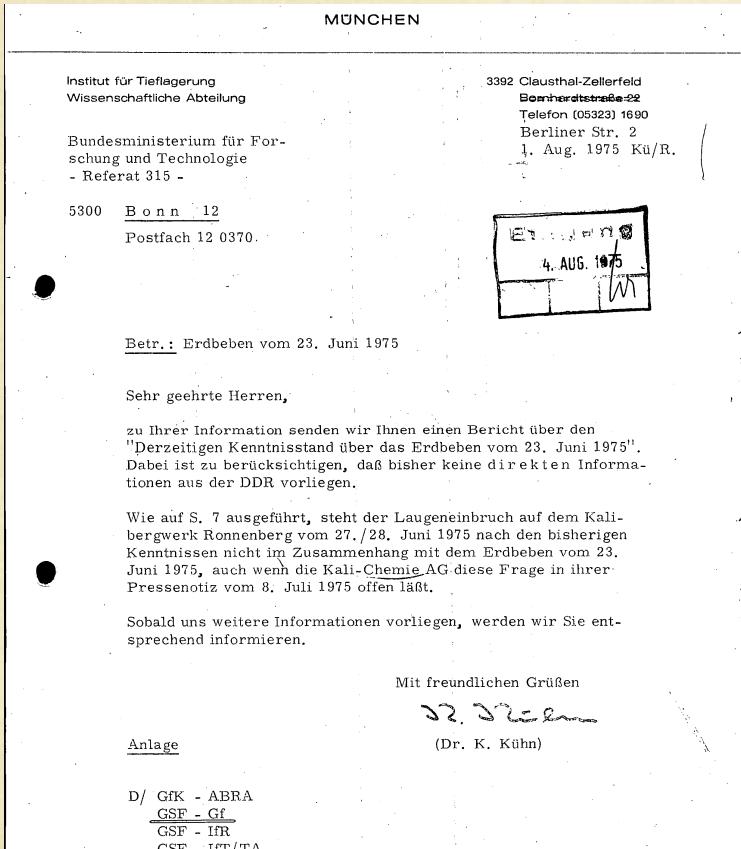


# Exploratory Study

Letterhead segmentation for legacy correspondence

20

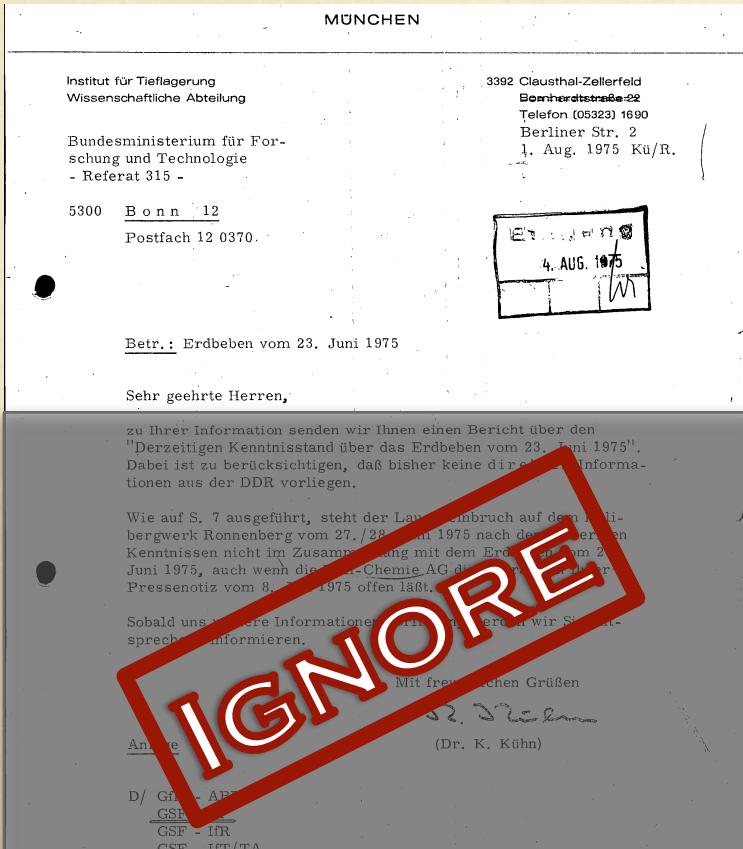
# Data



- Want to identify letterhead elements that form a unit
- 24 letters from an initial batch of scanned documents (approx. 80 documents)
- OCR optimised by external project partner
- Text body stripped away, just letterheads

21

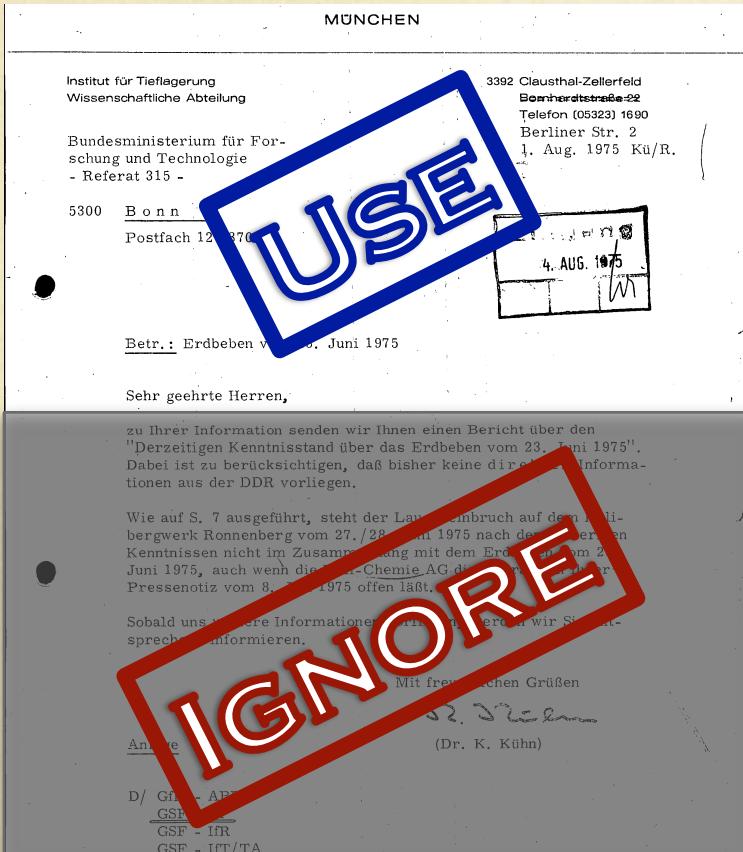
# Data



- Want to identify letterhead elements that form a unit
- 24 letters from an initial batch of scanned documents (approx. 80 documents)
- OCR optimised by external project partner
- Text body stripped away, just letterheads

22

# Data



- Want to identify letterhead elements that form a unit
- 24 letters from an initial batch of scanned documents (approx. 80 documents)
- OCR optimised by external project partner
- Text body stripped away, just letterheads

23

# Method

```
<span class='ocr line'  
      title='bbox  
261 2648 1064 2719'  
      style=  
'position:absolute;  
left:93.2142857143px;  
top:313.928571429px'>  
  Forschung und</  
  span><br />
```

Fig.: Snapshot from hOCR output

- Unsupervised clustering approach
- Use only positional information (for now)
- Agglomerative, bottom-up clustering
  - Complete-linkage
  - Euclidian distance

# Method

```
<span class='ocr line'  
      title='bbox  
261 2648 1064 2719'  
      style=  
      'position:absolute;  
left:93.2142857143px;  
top:313.928571429px'>  
      Forschung und</  
      span><br />
```

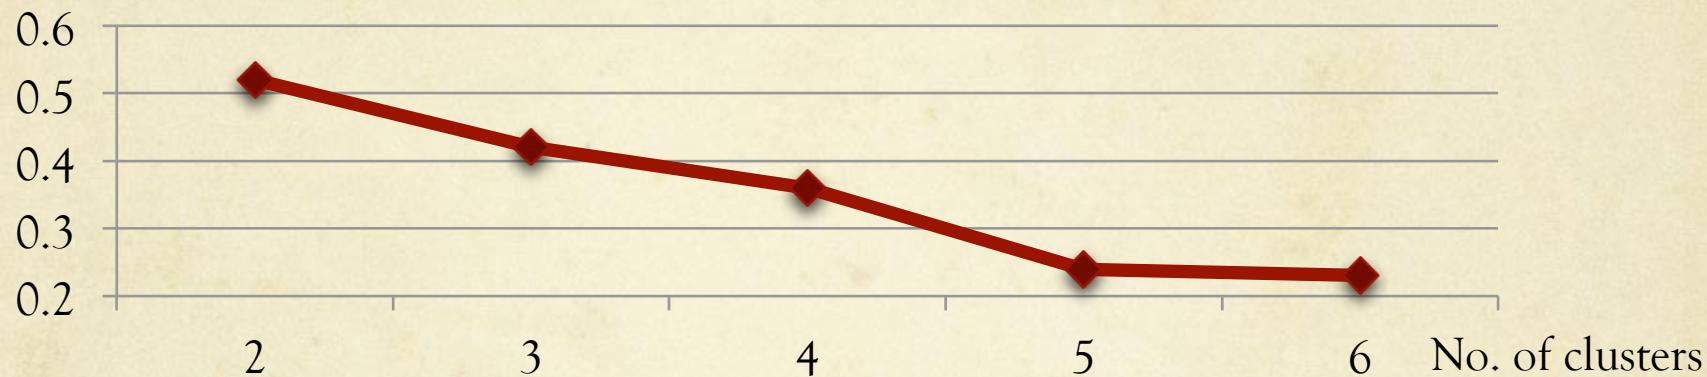
Fig.: Snapshot from hOCR output

- Unsupervised clustering approach
- Use only positional information (for now)
- Agglomerative, bottom-up clustering
  - Complete-linkage
  - Euclidian distance

# Method

Avg. within  
cluster  
variance

Doc. #3

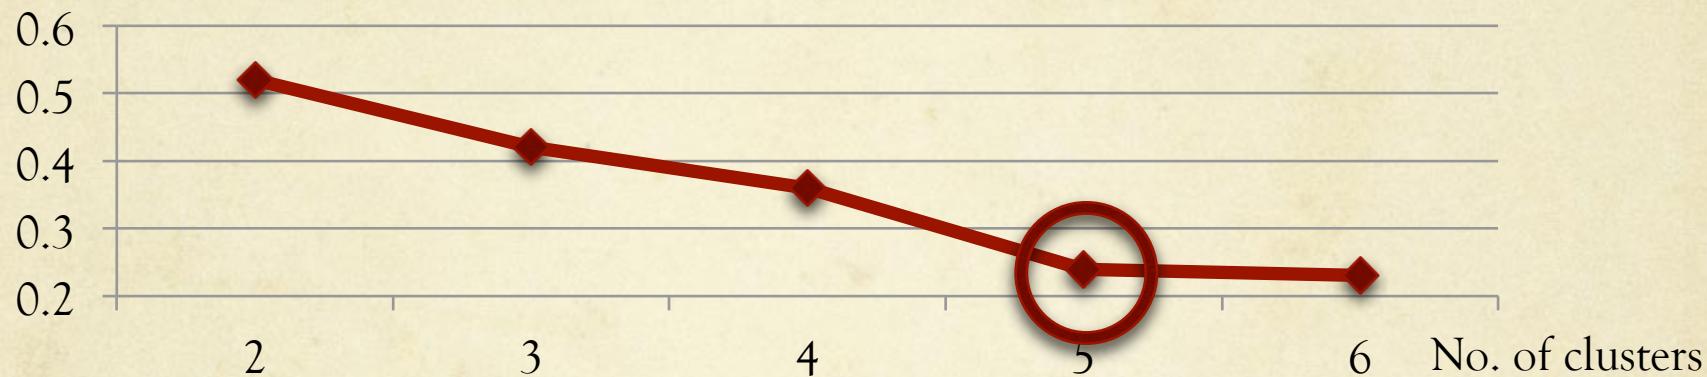


- “Flatten” clustering by identifying significant increase in average within cluster variance (“spot the elbow joint”)
- This is likely to indicate that two clusters far away from each other have erroneously been merged

# Method

Avg. within  
cluster  
variance

Doc. #3

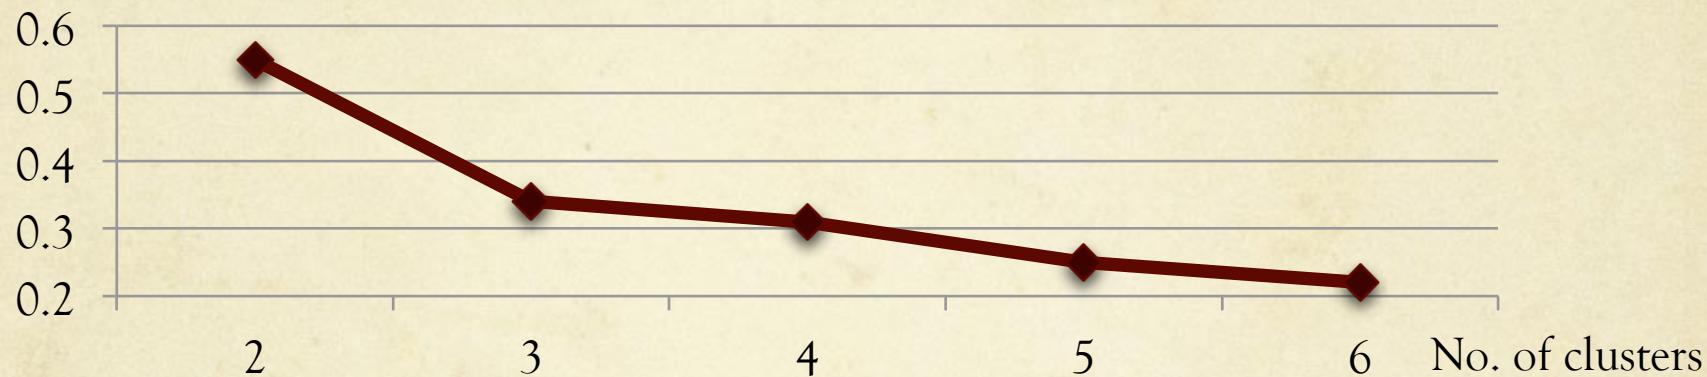


- “Flatten” clustering by identifying significant increase in average within cluster variance (“spot the elbow joint”)
- This is likely to indicate that two clusters far away from each other have erroneously been merged

# Method

Avg. within  
cluster  
variance

Doc. #54

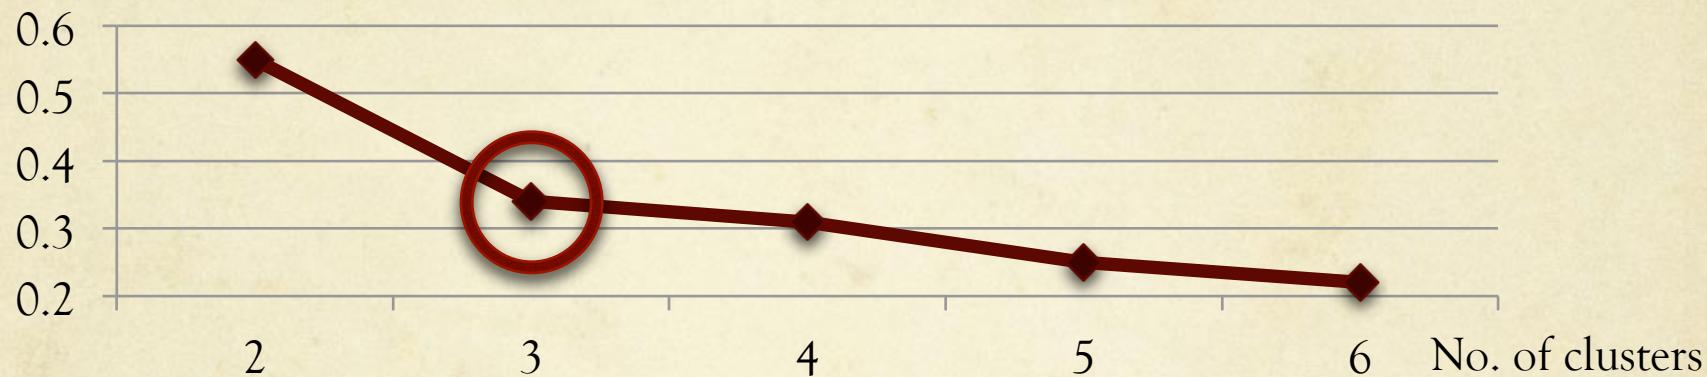


- “Flatten” clustering by identifying significant increase in average within cluster variance (“spot the elbow joint”)
- This is likely to indicate that two clusters far away from each other have erroneously been merged

# Method

Avg. within  
cluster  
variance

Doc. #54



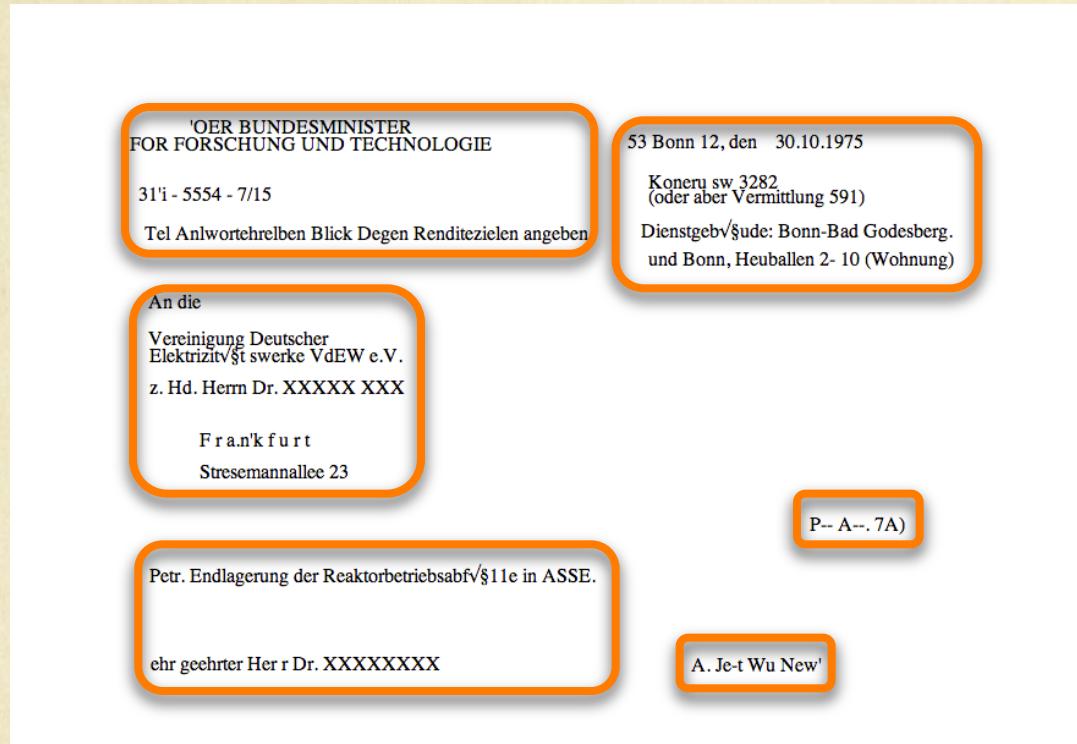
- “Flatten” clustering by identifying significant increase in average within cluster variance (“spot the elbow joint”)
- This is likely to indicate that two clusters far away from each other have erroneously been merged

# Example Segmentation

OER BUNDESMINISTER  
FOR FORSCHUNG UND TECHNOLOGIE  
31'i - 5554 - 7/15  
Tel Anwortehebeln Blick Degen Renditezielen angeben  
An die  
Vereinigung Deutscher  
Elektrizit/§tswerke VdEW e.V.  
z. Hd. Herrn Dr. XXXXX XXX  
  
F r a.n'k f u r t  
Stresemannallee 23  
  
Petr. Endlagerung der Reaktorbetriebsabf/§11e in ASSE.  
  
ehr geehrter Her r Dr. XXXXXXXXX  
A . Je-t Wu New'

No. of clusters	Within cluster variance

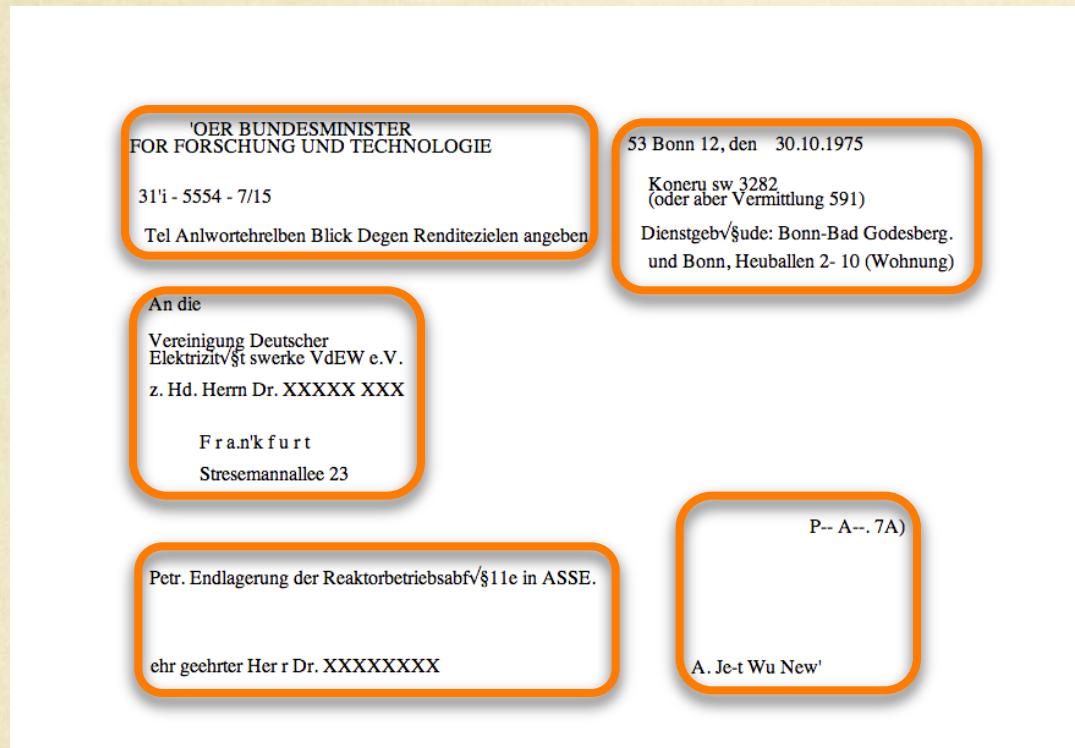
# Example Segmentation



No. of clusters	Within cluster variance
6	0.23

31

# Example Segmentation



No. of clusters	Within cluster variance
6	0.23
5	0.24

32

# Example Segmentation

OER BUNDESMINISTER  
OER FORSCHUNG UND TECHNOLOGIE  
31'i - 5554 - 7/15  
Tel Anworte hre lben Blick Degen Renditezielen angeben  
An die  
Vereinigung Deutscher  
Elektrizittswerke VdEW e.V.  
z. Hd. Herrn Dr. XXXXX XXX  
F r a.n'k f u r t  
Stremannallee 23

53 Bonn 12, den 30.10.1975  
Konferenz 3282  
(oder aber Vermittlung 591)  
Dienstgebude: Bonn-Bad Godesberg.  
und Bonn, Heuballen 2- 10 (Wohnung)

Petr. Endlagerung der Reaktorbetriebsabfule in ASSE.  
ehr geehrter Herr Dr. XXXXXXXXX  
P. A. 7A  
A. Je-t Wu New'

No. of clusters	Within cluster variance
6	0.23
5	0.24
4	0.36

33

# Example Segmentation

OER BUNDESMINISTER  
FOR FORSCHUNG UND TECHNOLOGIE  
31'i - 5554 - 7/15  
Tel Anworte hre lben Blick Degen Renditezielen angeben  
An die  
Vereinigung Deutscher  
Elektrizittswerke VdEW e.V.  
z. Hd. Herrn Dr. XXXXX XXX  
F r a n k f u r t  
Stresemannallee 23

Petr. Endlagerung der Reaktorbetriebsabfu 11c in ASSE.  
ehr geehrter Herr Dr. XXXXXXXXX

Konferenzsw. 3282  
(oder aber Vermittlung 591)  
Dienstgebude: Bonn-Bad Godesberg.  
und Bonn, Heuballen 2- 10 (Wohnung)

P- A- , 7A)  
A . Je-t Wu New'

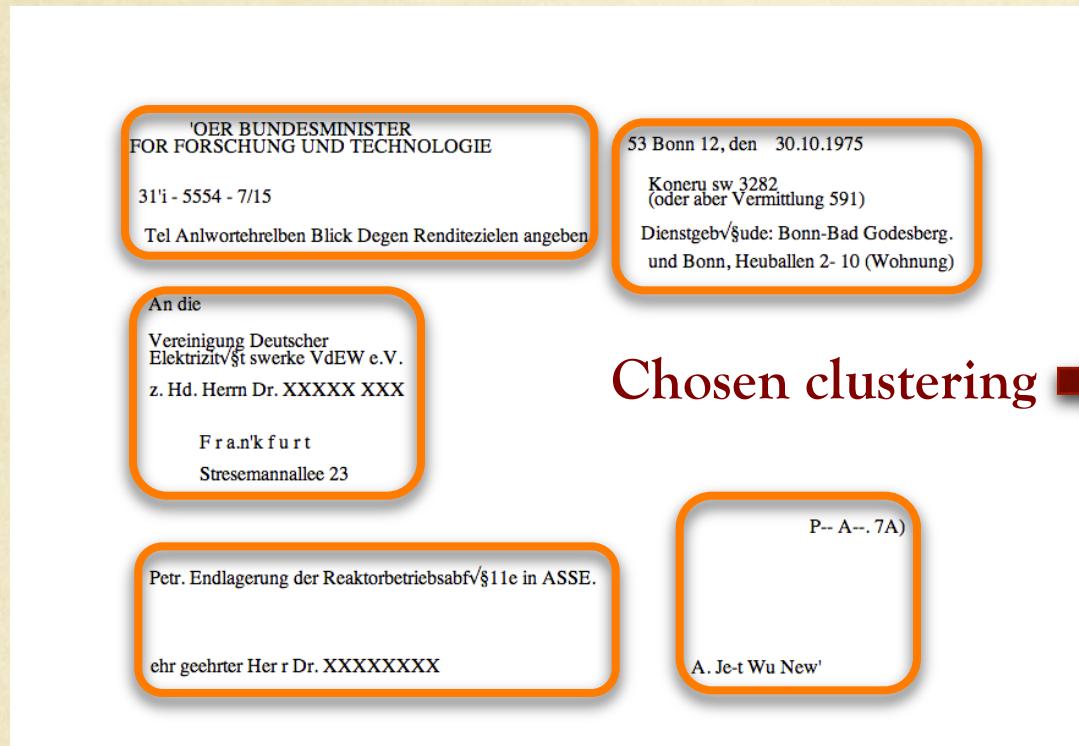
No. of clusters	Within cluster variance
6	0.23
5	0.24
4	0.36



Significant  
increase

34

# Example Segmentation



Chosen clustering →

No. of clusters	Within cluster variance
6	0.23
5	0.24
4	0.36

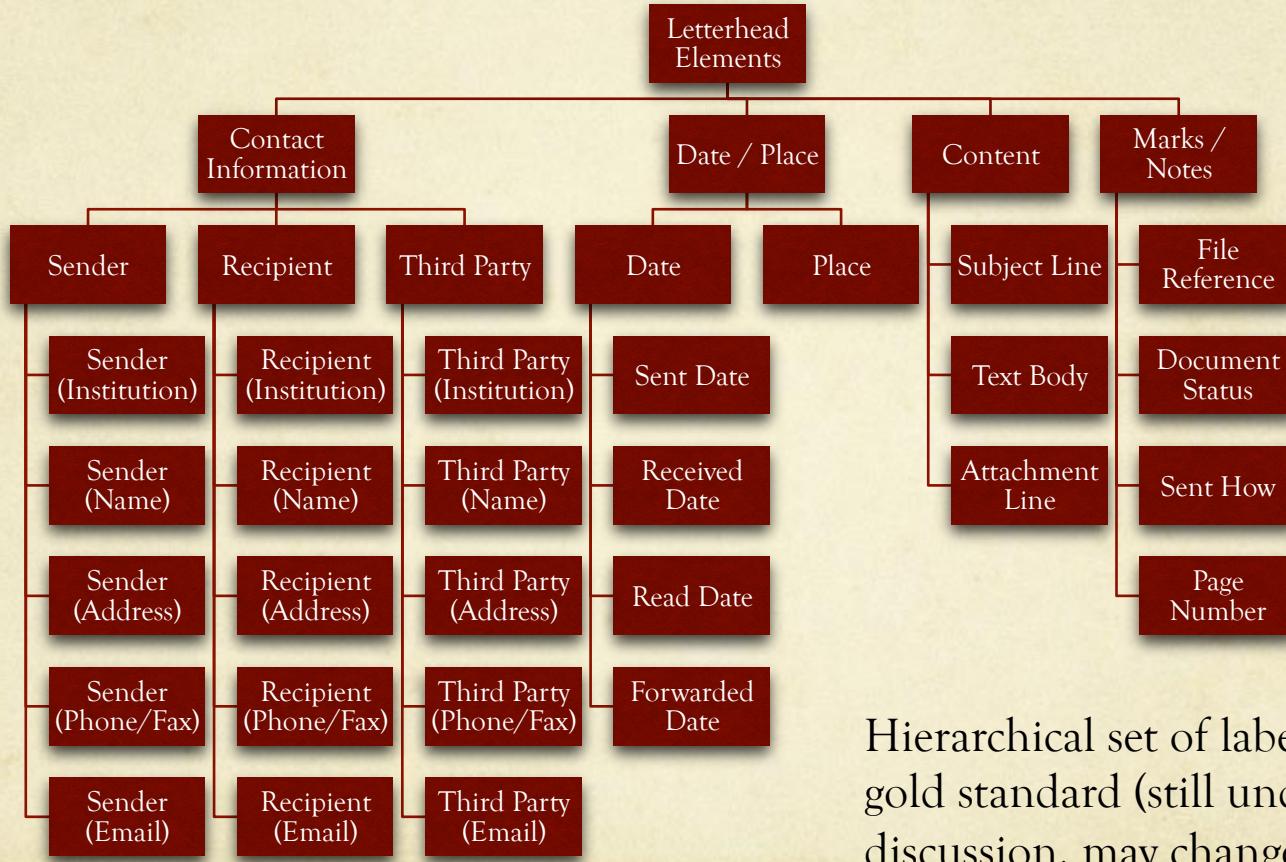
# Future Work



- Currently: Classify letterhead segments according to their “semantics” (address, date etc.) using Naïve Bayes and similar
- Layout and content analysis (possibly) not separate
- Next step: Create a gold standard for a small set of letters (ca. 60) and letterhead elements (ca. 1000-1500)
- Evaluate against gold standard

36

# Future Work



Hierarchical set of labels for  
gold standard (still under  
discussion, may change)

37

# Future Work



- Currently: Classify letterhead segments according to their “semantics” (address, date etc.) using Naïve Bayes and similar
- Layout and content analysis (possibly) not separate
- Next step: Create a gold standard for a small set of letters (ca. 60) and letterhead elements (ca. 1000-1500)
- Evaluate against gold standard

38

**Acta sunt sci**

**Thank you for your attention**

Questions? Comments?

**39**

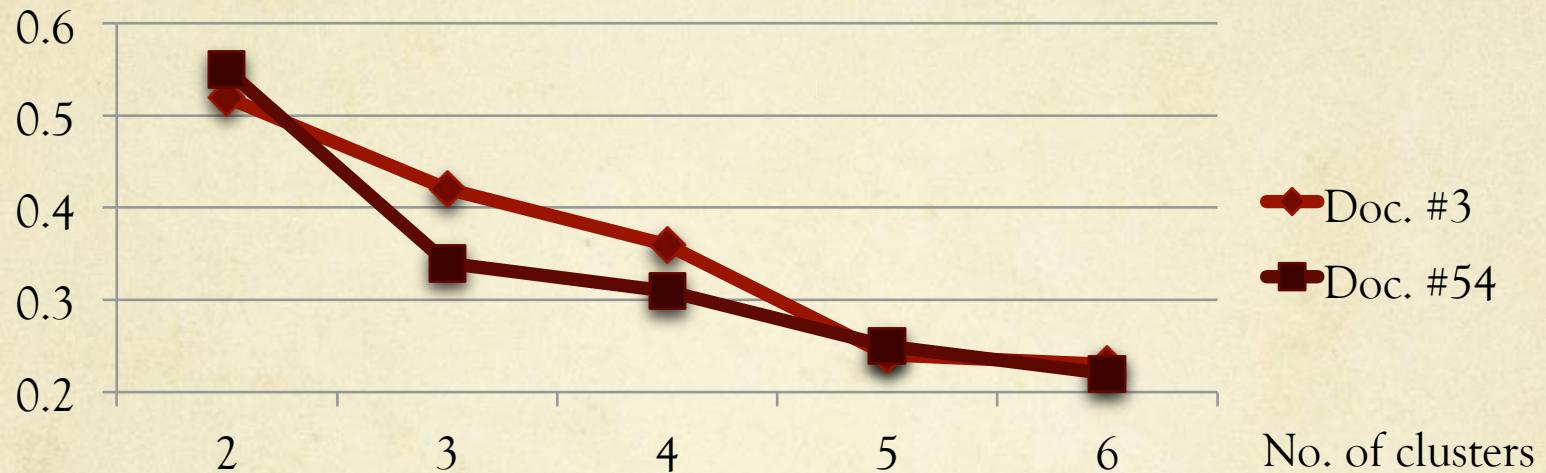


# Back-Up / Alternative Slides

40

Avg. within  
cluster  
variance

# Method



- “Flatten” clustering by identifying significant increase in average within cluster variance (“spot the elbow joint”)
- This indicates that two clusters far away from each other have (erroneously?) been merged