

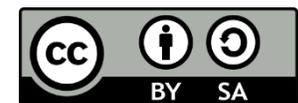
Forschungsdaten



aus Digitalisaten

Jan Kamlah, Stefan Weil
Universitätsbibliothek Mannheim

E-Science-Tage Heidelberg, 28.03.2019

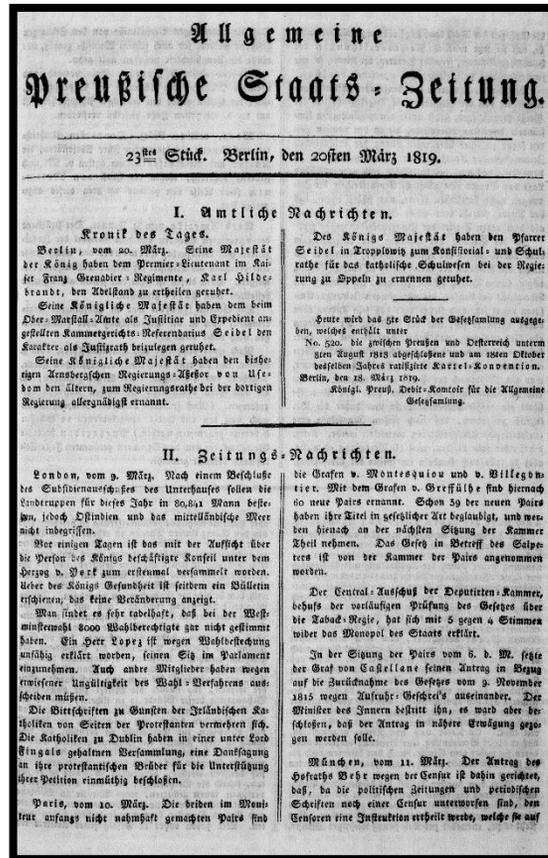


Motivation für Texterkennung und Strukturierung bei Digitalisierungsprojekten

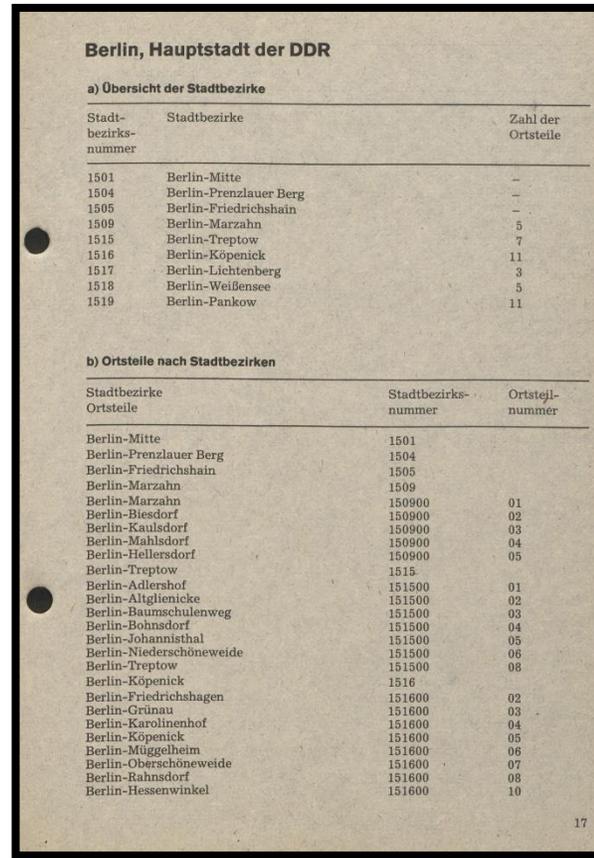
- **Digitalisate**
 - Online Zugriff weltweit
 - Digitale Bestandserhaltung
- **Text durch Texterkennung (OCR)**
 - Recherchemöglichkeiten (Such-Funktion)
 - Kopiermöglichkeiten für den Volltext
- **Strukturierte Daten aus dem Volltext**
 - Strukturierte Suche
 - Auswertungen für Forschungsfragen

Übersicht

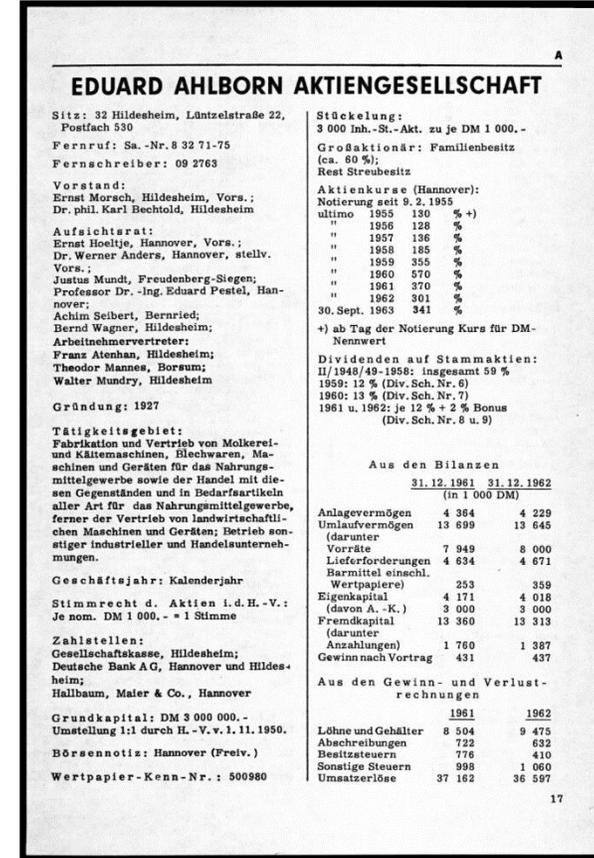
Digitalisate für Forschungsdaten an der UB Mannheim



Reichsanzeiger



Gemeindeverzeichnisse



Aktienführer

Aktienführer-Datenarchiv-Projekt

- Was ist der **Aktienführer**?
 - Jährlich erscheinende Publikation (Bücher bzw. CDs)
 - Firmenprofile aller an deutschen Börsen notierten Aktiengesellschaften
 - Wer war im Vorstand, Aufsichtsrat?
 - Aktienkurse, Bilanzdaten
- Was ist das **Ergebnis des Projekts**?
 - Zugang zu den **Unternehmensprofilen der letzten 140 Jahre** (1870–2018)
 - Bereitstellung einer **feinstrukturierten Datenbank der letzten 60 Jahre** (1956–2018)
- Was ist der **Rahmen des Projekts**?

DFG Deutsche Forschungsgemeinschaft

 - 1. Projektphase: 2013–2016 (24 M)
 - 2. Projektphase: 2017–2019 (24 M)

A

EDUARD AHLBORN AKTIENGESELLSCHAFT

Sitz: 32 Hildesheim, Lüntzelstraße 22, Postfach 530
 Fernruf: Sa.-Nr. 8 32 71-75
 Fernschreiber: 09 2763

Vorstand:
 Ernst Morsch, Hildesheim, Vors.;
 Dr. phil. Karl Bechtold, Hildesheim

Aufsichtsrat:
 Ernst Hoeltje, Hannover, Vors.;
 Dr. Werner Anders, Hannover, stellv. Vors.;

Justus Mundt, Freudenberg-Siegen;
 Professor Dr. -Ing. Eduard Pestel, Hannover;
 Achim Seibert, Bernried;
 Bernd Wagner, Hildesheim;
 Arbeitnehmervertreter:
 Franz Atenhan, Hildesheim;
 Theodor Mannes, Borsum;
 Walter Mundry, Hildesheim

Gründung: 1927

Tätigkeitsgebiet:
 Fabrikation und Vertrieb von Molke- und Kältemaschinen, Blechwaren, Maschinen und Geräten für das Nahrungsmittelgewerbe sowie der Handel mit diesen Gegenständen und in Bedarfsartikeln aller Art für das Nahrungsmittelgewerbe, ferner der Vertrieb von landwirtschaftlichen Maschinen und Geräten; Betrieb sonstiger industrieller und Handelsunternehmungen.

Geschäftsjahr: Kalenderjahr
 Stimmrecht d. Aktien i. d. H. - V.: Je nom. DM 1 000. - = 1 Stimme

Zahlstellen:
 Gesellschaftskasse, Hildesheim;
 Deutsche Bank AG, Hannover und Hildesheim;
 Hallbaum, Maier & Co., Hannover

Grundkapital: DM 3 000 000.-
 Umstellung l:1 durch H. - V. v. I. 11. 1950.
 Börsennotiz: Hannover (Freiv.)
 Wertpapier-Kenn-Nr.: 500980

Stückelung:
 3 000 Inh.-St.-Akt. zu je DM 1 000.-
 Großaktionär: Familienbesitz (ca. 60 %);
 Rest Streubesitz

Aktienkurse (Hannover):
 Notierung seit 9. 2. 1955

ultimo	1955	130	% +)
"	1956	128	%
"	1957	136	%
"	1958	135	%
"	1959	355	%
"	1960	570	%
"	1961	370	%
"	1962	301	%
30. Sept. 1963	341	%	

+) ab Tag der Notierung Kurs für DM-Nennwert

Dividenden auf Stammaktien:
 II/1948/49-1958: insgesamt 59 %
 1959: 12 % (Div. Sch. Nr. 6)
 1960: 13 % (Div. Sch. Nr. 7)
 1961 u. 1962: je 12 % + 2 % Bonus (Div. Sch. Nr. 8 u. 9)

Aus den Bilanzen

	31. 12. 1961	31. 12. 1962
	(in 1 000 DM)	
Anlagevermögen	4 364	4 229
Umlaufvermögen	13 699	13 645
(darunter		
Vorräte	7 949	8 000
Lieferforderungen	4 634	4 671
Barmittel einschl. Wertpapiere)	253	359
Eigenkapital	4 171	4 018
(davon A. - K.)	3 000	3 000
Fremdkapital	13 360	13 313
(darunter		
Anzahlungen)	1 760	1 387
Gewinn nach Vortrag	431	437

Aus den Gewinn- und Verlustrechnungen

	1961	1962
Löhne und Gehälter	8 504	9 475
Abschreibungen	722	632
Bestzsteuer	776	410
Sonstige Steuern	998	1 060
Umsatzerlöse	37 162	36 597

17

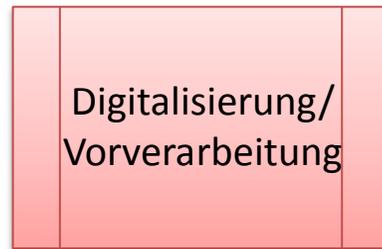
Firmenprofil aus dem Aktienführer 1964 (Buch)



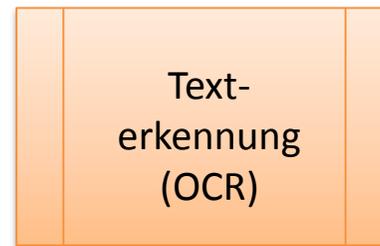
Prozesskette Forschungsdaten aus Digitalisaten



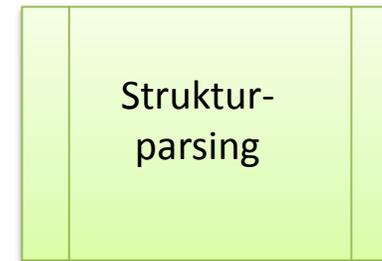
Bücher



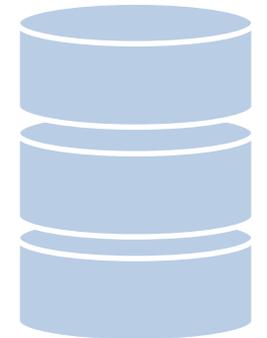
Generierung
digitaler Ausgangsformate



Generierung
der digitalen Inhalte

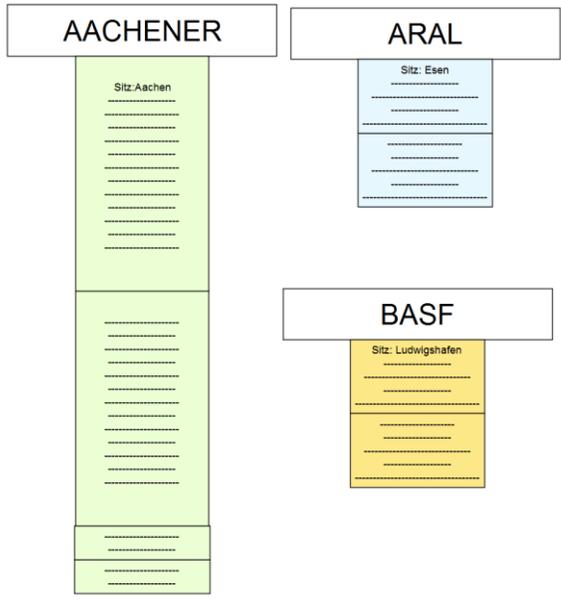
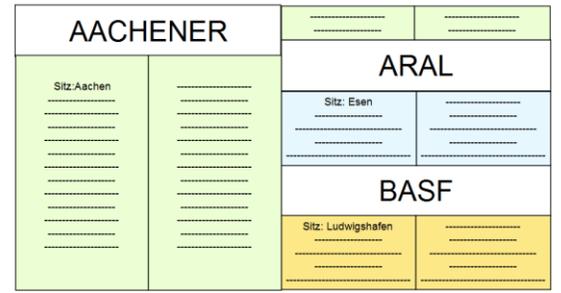


Strukturierung
der digitalen Inhalte
(Datenextraktion)



Befüllen
der Datenbank

EDUARD AHLBORN AKTIENGESELLSCHAFT	
Sitz: 32 Hildesheim, Lüntzelstraße 22, Postfach 530	
Fernruf: Sa.-Nr. 8 32 71-75	
Fernschreiber: 09 2763	
Vorstand: Ernst Morach, Hildesheim, Vors.; Dr. phil. Karl Bechtold, Hildesheim	
Aufsichtsrat: Ernst Hoelje, Hannover, Vors.; Dr. Werner Anders, Hannover, stellv. Vors.; Justus Mundt, Freudenberg-Siegen, Professor Dr.-Ing. Eduard Pestel, Hannover; Achim Seibert, Bernried; Bernd Wagner, Hildesheim; Arbeitsnehmervertreter: Franz Altenhan, Hildesheim; Theodor Mannes, Borsum; Walter Mundry, Hildesheim	
Gründung: 1927	
Tätigkeitsgebiet: Fabrikation und Vertrieb von Molkerie- und Kältemaschinen, Blechwaren, Maschinen und Geräten für das Nahrungsmittelgewerbe sowie der Handel mit diesen Gegenständen und in Bedarfsartikeln aller Art für das Nahrungsmittelgewerbe, ferner der Vertrieb von landwirtschaftlichen Maschinen und Geräten; Betrieb sonstiger industrieller und Handelsunternehmungen.	
Geschäftsjahr: Kalenderjahr	
Stimmrecht d. Aktien i. d. H.-V.: Je nom. DM 1 000,- = 1 Stimme	
Zahlstellen: Gesellschaftskasse, Hildesheim; Deutsche Bank AG, Hannover und Hildesheim; Hallbaum, Maier & Co., Hannover	
Grundkapital: DM 3 000 000,- Umstellung lt: durch H.-V.v. 1. 11. 1950.	
Börsennotiz: Hannover (Freiv.)	
Wertpapier-Kenn-Nr.: 500880	
Stückelung: 3 000 Inh.-St.-Akt. zu je DM 1 000,-	Großaktionär: Familienbesitz (ca. 60 %); Rest Streubesitz
Aktienkurse (Hannover): Notierung seit 9. 2. 1955	
ultimo 1955 130 %	
" 1956 128 %	
" 1957 136 %	
" 1958 185 %	
" 1959 355 %	
" 1960 570 %	
" 1961 370 %	
" 1962 301 %	
30. Sept. 1963 341 %	
*) ab Tag der Notierung Kurs für DM-Nennwert	
Dividenden auf Stammaktien: II/1948/49-1958: insgesamt 59 % 1959: 12 % (Div. Sch. Nr. 6) 1960: 13 % (Div. Sch. Nr. 7) 1961 u. 1962: je 12 % + 2 % Bonus (Div. Sch. Nr. 8 u. 9)	
Aus den Bilanzen	
	31. 12. 1961 31. 12. 1962
	(in 1 000 DM)
Anlagevermögen	4 364 4 229
Umlaufvermögen	13 699 13 645
(darunter	
Vorräte	7 849 8 000
Lieferforderungen	4 634 4 671
Barmittel einschl. Wertpapiere)	253 359
Eigenkapital	4 171 4 018
(davon A.-K.)	3 000 3 000
Fremdkapital	13 360 13 313
(darunter	
Anzahlungen)	1 760 1 387
Gewinnnach Vortrag	431 437
Aus den Gewinn- und Verlustrechnungen	
	1961 1962
Löhne und Gehälter	8 504 8 475
Abschreibungen	722 632
Beizateuern	776 410
Sonstige Steuern	998 1 060
Umsatzerlöse	37 162 36 597



EDUARD AHLBORN AKTIENGESELLSCHAFT	
Sitz: 32 Hildesheim, Lüntzelstraße 22, Postfach 530	
Fernruf: Sa.-Nr. 8 32 71-75	
Fernschreiber: 09 2763	
Vorstand: Ernst Morach, Hildesheim, Vors.; Dr. phil. Karl Bechtold, Hildesheim	
Aufsichtsrat: Ernst Hoelje, Hannover, Vors.; Dr. Werner Anders, Hannover, stellv. Vors.; Justus Mundt, Freudenberg-Siegen, Professor Dr.-Ing. Eduard Pestel, Hannover; Achim Seibert, Bernried; Bernd Wagner, Hildesheim; Arbeitsnehmervertreter: Franz Altenhan, Hildesheim; Theodor Mannes, Borsum; Walter Mundry, Hildesheim	
Gründung: 1927	
Tätigkeitsgebiet: Fabrikation und Vertrieb von Molkerie- und Kältemaschinen, Blechwaren, Maschinen und Geräten für das Nahrungsmittelgewerbe sowie der Handel mit diesen Gegenständen und in Bedarfsartikeln aller Art für das Nahrungsmittelgewerbe, ferner der Vertrieb von landwirtschaftlichen Maschinen und Geräten; Betrieb sonstiger industrieller und Handelsunternehmungen.	
Geschäftsjahr: Kalenderjahr	
Stimmrecht d. Aktien i. d. H.-V.: Je nom. DM 1 000,- = 1 Stimme	
Zahlstellen: Gesellschaftskasse, Hildesheim; Deutsche Bank AG, Hannover und Hildesheim; Hallbaum, Maier & Co., Hannover	
Grundkapital: DM 3 000 000,- Umstellung lt: durch H.-V.v. 1. 11. 1950.	
Börsennotiz: Hannover (Freiv.)	
Wertpapier-Kenn-Nr.: 500880	
Stückelung: 3 000 Inh.-St.-Akt. zu je DM 1 000,-	Großaktionär: Familienbesitz (ca. 60 %); Rest Streubesitz
Aktienkurse (Hannover): Notierung seit 9. 2. 1955	
ultimo 1955 130 %	
" 1956 128 %	
" 1957 136 %	
" 1958 185 %	
" 1959 355 %	
" 1960 570 %	
" 1961 370 %	
" 1962 301 %	
30. Sept. 1963 341 %	
*) ab Tag der Notierung Kurs für DM-Nennwert	
Dividenden auf Stammaktien: II/1948/49-1958: insgesamt 59 % 1959: 12 % (Div. Sch. Nr. 6) 1960: 13 % (Div. Sch. Nr. 7) 1961 u. 1962: je 12 % + 2 % Bonus (Div. Sch. Nr. 8 u. 9)	
Aus den Bilanzen	
	31. 12. 1961 31. 12. 1962
	(in 1 000 DM)
Anlagevermögen	4 364 4 229
Umlaufvermögen	13 699 13 645
(darunter	
Vorräte	7 849 8 000
Lieferforderungen	4 634 4 671
Barmittel einschl. Wertpapiere)	253 359
Eigenkapital	4 171 4 018
(davon A.-K.)	3 000 3 000
Fremdkapital	13 360 13 313
(darunter	
Anzahlungen)	1 760 1 387
Gewinnnach Vortrag	431 437
Aus den Gewinn- und Verlustrechnungen	
	1961 1962
Löhne und Gehälter	8 504 8 475
Abschreibungen	722 632
Beizateuern	776 410
Sonstige Steuern	998 1 060
Umsatzerlöse	37 162 36 597

OCR Software (Übersicht)

kommerzielle
Software

fett = eingesetzt in Bibliotheken

ABBYY Finereader
BIT-Alpha
Readiris
OmniPage

Adobe Acrobat
CorelDraw
Microsoft OneNote
...

Tesseract
OCROpus / Kraken /
Calamari
CuneiForm
...

freie Software

ABBYY Cloud OCR
Google Cloud Vision
Microsoft Azure Computer Vision
OCR.space Online OCR ...

Cloud OCR

Tesseract OCR

- Open Source
- Komplettlösung „All-in-1“
- Mehr als 100 Sprachen / mehr als 30 Schriften
- Liest Bilder in allen gängigen Formaten (nicht PDF!)
- Erzeugt Text, PDF, hOCR, ALTO, TSV
- Große, weltweite Anwender-Community
- Technologisch aktuell (Texterkennung mit neuronalem Netz)
- Aktive Weiterentwicklung u. a. im DFG-Projekt OCR-D

Tesseract an der UB Mannheim

- Verwendung im DFG-Projekt „Aktienführer“
<https://digi.bib.uni-mannheim.de/aktienfuehrer/>
- Volltexte für Deutscher Reichsanzeiger und Vorgänger
<https://digi.bib.uni-mannheim.de/periodika/reichsanzeiger>

- DFG-Projekt „OCR-D“ <http://www.ocr-d.de/>,

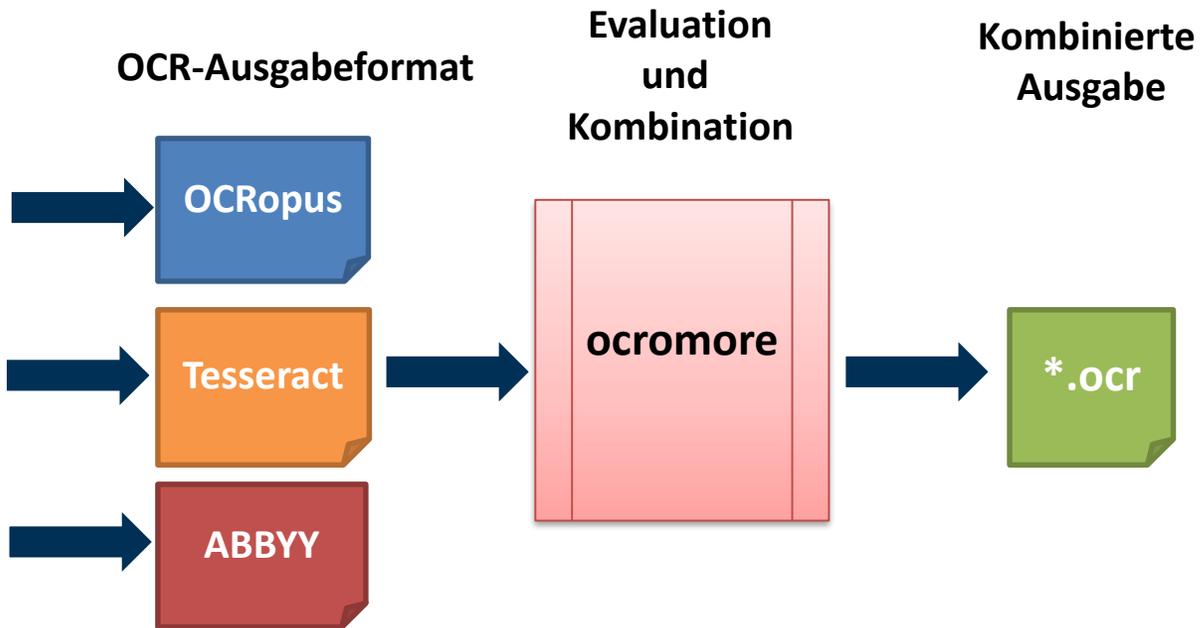


OCR-D

Koordinierte Förderinitiative zur Weiterentwicklung
von Verfahren der Optical Character Recognition (OCR)

Modulprojekt „Optimierter Einsatz von OCR-Verfahren – Tesseract als Komponente im OCR-D-Workflow“:
Schnittstellen, Stabilität, Performance und praktische Einsetzbarkeit,
Erweiterungen wie z. B. Konfidenzen

ocromore – Kombination und Optimierung von OCR-Resultaten



```

R1: Eduard Ahlborn Axtiengesellschaft
R2: Edoard Anlborn Aktiengesellschaft
R3: Eduard Ahlbrn Aktiengesellschaft
  
```

Input: Mehrere OCR-Resultate

Edu ard	A hlborn	A xtiengesellschaft
Ed oard	An lborn	Ak tiengesellschaft
Edu ard	A hlb rn	Ak tiengesellschaft

Aufteilung und Vergleich auf Wortebene mit Textausrichtung (Alignment)

u	99; 00;
o	00; 60;
u	90; 00;

Wahl der Zeichen nach Konfidenz der Verfahren

Eduard	Ahlborn	Aktiengesellschaft
--------	---------	--------------------

ocromore – Verbesserung der Zeichengenauigkeit

OCR-Engine	Aktienführer (AKF)	UNLV
ABBYY	99,35 %	98,46 %
OCROPUS (default en-model)	-	92,49 %
OCROPUS (trained)	98,76 %	-
Tesseract	99,00 %	98,23 %
ocromore (MSA)	99,60 %	98,65 %

- Erhöhung der Zeichengenauigkeit (AKF) : 0,25 %
- Erhöhung der Wortgenauigkeit (AKF) : 2,03 %
- Erhöhung der Zeichengenauigkeit (UNLV) : 0,19 %
- Fehlerreduktion der Zeichengenauigkeit (AKF) : 38,5 %

AKF: 18 große Dateien (mit insgesamt ca. 100.000 Zeichen) 1957-1976 alle 3-4 Jahre
UNLV: University of Nevada Las Vegas standardized test set

docxstruct – Segmentklassifizierung und Datenextraktion

EDUARD AHLBORN AKTIENGESELLSCHAFT

Sitz: 32 Hildesheim, Lüntzelstraße 22,
Postfach 530

Fernruf: Sa.-Nr.8 32 71-75
Fernschreiber: 09 2763

Vorstand:

Ernst Morsch, Hildesheim, Vors.;
Dr. phil. Karl Bechtold, Hildesheim

Aufsichtsrat:

Ernst Hoeltje, Hannover, Vors.;
Dr. Werner Anders, Hannover, stellv.

Vors.;

Justus Mundt, Freudenberg-Siegen;
Professor Dr. -Ing. Eduard Pestel, Han-
nover;

Achim Seibert, Bernried;
Bernd Wagner, Hildesheim;

Arbeitnehmervertreter:
Franz Atenhan, Hildesheim;
Theodor Mannes, Borsum;
Walter Mundry, Hildesheim

Gründung: 1927

DOC X STRUCT

```
"Sitz": [
  {
    "numID": "32",
    "city": "Hildesheim",
    "street": "Lüntzelstraße 22",
    "additional_info": [
      "Postfach 530"
    ]
  }
],
```

```
"Vorstand": [
  {
    "name": "Ernst Morsch",
    "first_name": "Ernst",
    "last_name": "Morsch",
    "city": "Hildesheim",
    "funct": "Vors."
  },
  {
    "name": "Karl Bechtold",
    "first_name": "Karl",
    "last_name": "Bechtold",
    "city": "Hildesheim",
    "title": "Dr.phil."
  }
],
```

Segmentierung des Aktienführers

28.03.2019

Strukturerkennung von Sitz und Vorstand

12

Ein Blick **zurück** und nach **vorne**

Derzeitiger Stand:

- Alle Tools als **Open Source** öffentlich auf GitHub:
<https://github.com/UB-Mannheim/Aktienfuehrer-Datenarchiv-Tools>
<https://github.com/tesseract-ocr/tesseract>



Ausblick:

- Ausbau des **Forschungsdatenzentrums** (FDZ) der UB Mannheim; Aktienführer als Kernstück
- **BERD-Center** (Business and Economic Research Data Center)
 - Kooperationsprojekt Universität Mannheim und ZEW, Landesförderung BW
 - Aufbau eines Kompetenzzentrums für Forschungsdaten der Wirtschaftswissenschaften
 - Möglichkeit zur Nachnutzung der entwickelten Softwaretools aus Aktienführer-Datenarchiv-Projekt
- Kooperationsprojekt **OCR-BW** (gemeinsam mit Tübingen, Landesprojekt BW, bewilligt)
 - Aufbau eines Kompetenzzentrums Volltexterkennung für Bibliotheken und Archive
- DFG-Projekt **Reichsanzeiger** (bewilligt)

Literatur

- Weil, S., & Zumstein, P. (2016). Mit freier Software Text in Digitalisaten erkennen. <https://speakerdeck.com/zuphilip/mit-freier-software-text-in-digitalisaten-erkennen-ocr-praxis-an-der-ub-mannheim>
- Baierer, K., & Zumstein, P. (2016). Verbesserung der OCR in digitalen Sammlungen von Bibliotheken. *027.7 Zeitschrift für Bibliothekskultur / Journal for Library Culture*, 4(2), 72-83. <https://doi.org/10.12685/027.7-4-2-155>
- Kamlah, J., Stegmüller, J. (2018). Ochromore – Combining multiple OCR-engine results to improve character recognition accuracy. <https://zenodo.org/record/1493860>
- Kamlah, J., Stegmüller, J., Schumm, I., Zumstein, P. (2019). Automatisierte Optimierung und Strukturierung von OCR-Ergebnissen mit nachnutzbaren Werkzeugen. <https://ub-madoc.bib.uni-mannheim.de/48940>
- Weil, S. (2019). Vom Bild zum Text. Automatisierte Texterkennung in historischen Drucken mit der freien Software Tesseract. <https://nbn-resolving.org/urn:nbn:de:0290-opus4-163511>

Bildquellen

- Titelseite:
<https://pixabay.com/de/vectors/flach-design-symbol-icon-www-2126884/>
<https://pixabay.com/de/vectors/flach-design-symbol-icon-www-2126880/>
<https://pixabay.com/de/vectors/werkzeug-schraubenschl%C3%BCssel-3456474/>
<https://commons.wikimedia.org/wiki/File:Opensource.svg>
- DFG-Logo: <https://www.dfg.de/>
- GitHub Logos: <https://github.com/logos>
- OCR-D Logo: <http://www.ocr-d.de/>