

Extracting research data from historical documents with eScriptorium and Python

Jan Kamlah, Thomas Schmidt and Renat Shigapov
University Library Mannheim

24.11.2022

- 
- 1. Introduction & Digitalization**
 - 2. Layout segmentation and OCR via eScriptorium**
 - 3. Extraction and structuring via Python**
 - 4. Summary**

1. Introduction & Digitalization

Alle Inhalte dieser Präsentation stehen unter der [Lizenz Creative Commons BY 4.0 International](#), sofern nicht anders angegeben.



1. Introduction & Digitalization

- Request for extraction of structured research data from
"Die Maschinen-Industrie im Deutschen Reich von 1937"
by Prof. Jochen Streb (Chair of Economic History @
University of Mannheim)
- Cooperation project between BERD@NFDI and OCR-D
module project "work-specific training" @ UB Mannheim
- Digitization (654 pages) by UB Mannheim

<p>Phönix — Pincuss</p> <p>Phönix-Werk G. m. b. H., Spezialfabrik moderner Trocken- Apparate, Meerane (Sa.).</p> <p>Fernruf: 3284. Drahtanschrift: phönixwerk Gründung: 1907. Fabrikationsprogramm: Trockenapparate; Holzbearbeitungs-Maschinen. Kapital: RM 17 500.—. Anteilseigner: C. R. Nestmann, Meerane (100%). Geschäftsführer: Obering, A. Wackermann. Prokurist: J. Frenzel. Bankverbindungen: Meeraner Bank A.-G., Reichsbank, Meerane. Postcheck-Konto: 115 485 Leipzig. Geschäftsjahr: 1./1.—31./12. Grundbesitz: 3700 qm, davon 1462 qm bebaut. Anlagen: Fabrikationsräume mit Montagehalle, elektr. Schleißpresse, Zellerei, u. anderes allgemeines Trocknungs- u. Zellerei-Gebäude. Eigene Vertretungen: In Berlin: Willy Böckel, W 30, Martin Luther Str. 15. Besondere Angaben: Gegründet als Spezialfirma moderner Trocknungsanlagen. Hergestellt wurden Schlangenbündel-Trockenapparate System Otto und Getreide-trocknungsanlagen. 1921 erfolgte mit dem Erwerb der Firma Schenck die Aufnahme der Fabrikation von Holzherbeutungsmaschinen. 1932 übernahm das Werk zusätzlich die Herstellung von Bewoid-Apparaturen für die Papierindustrie nach den Patenten Dr. Bruno Wiegner, Berlin.</p>	<p>Otto Pieron siehe Maschinenfabrik</p>
<p>Paul Pietzschmann Wasserwerksbau, Berlin-Spandau, Schönwalder Str. 34.</p> <p>Fernruf: 37 68 71. Gründung: 1932. Fabrikationsprogramm: Entwurf und Bau von Trink- und Gebrauchswasserwerken jeder Größe. Entsiedlungsanlagen einschl. der erforderlichen Antriebsanlagen (Dampf — Diesel — Wasserkraft, Hoch- und Niederspannung). Inhaber: Ing. Paul Pietzschmann. Bankverbindungen: Dresdner Bank, Spandauer Bank, Spandau.</p>	<p>Paul Pietzschmann Wasserwerksbau, Berlin-Spandau, Schönwalder Str. 34.</p> <p>Fernruf: 37 68 71. Gründung: 1932. Fabrikationsprogramm: Entwurf und Bau von Trink- und Gebrauchswasserwerken jeder Größe. Entsiedlungsanlagen einschl. der erforderlichen Antriebsanlagen (Dampf — Diesel — Wasserkraft, Hoch- und Niederspannung). Inhaber: Ing. Paul Pietzschmann. Bankverbindungen: Dresdner Bank, Spandauer Bank, Spandau.</p>
<p>Anton Piller Maschinenfabrik, Osterode (Harz), Abgunt 24.</p> <p>Fernruf: 211. Drahtanschrift: apo Gründung: 1909. Fabrikationsprogramm: Ventilatoren für Heizungs-, Lüftungs-, Absauge u. sonstige Zwecke. Bankverbindung: Reichsbank, Städt. Sparkasse, Osterode a. H. Postcheck-Konto: 40 278 Hannover.</p>	<p>Anton Piller Maschinenfabrik, Osterode (Harz), Abgunt 24.</p> <p>Fernruf: 211. Drahtanschrift: apo Gründung: 1909. Fabrikationsprogramm: Ventilatoren für Heizungs-, Lüftungs-, Absauge u. sonstige Zwecke. Bankverbindung: Reichsbank, Städt. Sparkasse, Osterode a. H. Postcheck-Konto: 40 278 Hannover.</p>
<p>Pilot. G. m. b. H. siehe Maschinenfabrik</p>	<p>Pilot. G. m. b. H. siehe Maschinenfabrik</p>
<p>Friedrich Piltz & Sohn K.-G., Heidenheim a. d. Brenz, Friedrichstr. 9.</p> <p>Fernruf: 637. Drahtanschrift: piltz Gründung: 1863. Fabrikationsprogramm: Genauigkeitswerkzeuge für Herstellung u. Kontrolle von Gewinden; Gewindesteifel, Gewindestecker, Schraubenschlüssel. Gesellschafter: Otto u. Walther Piltz. Geschäftsführer: Die Gesellschafter. Bankverbindungen: Reichsbank, Deutsche Bank u. Disconto-Ges., Heidenheim. Postcheck-Konto: 2178 Stuttgart. Geschäftsjahr: Kalenderjahr.</p>	<p>Friedrich Piltz & Sohn K.-G., Heidenheim a. d. Brenz, Friedrichstr. 9.</p> <p>Fernruf: 637. Drahtanschrift: piltz Gründung: 1863. Fabrikationsprogramm: Genauigkeitswerkzeuge für Herstellung u. Kontrolle von Gewinden; Gewindesteifel, Gewindestecker, Schraubenschlüssel. Gesellschafter: Otto u. Walther Piltz. Geschäftsführer: Die Gesellschafter. Bankverbindungen: Reichsbank, Deutsche Bank u. Disconto-Ges., Heidenheim. Postcheck-Konto: 2178 Stuttgart. Geschäftsjahr: Kalenderjahr.</p>
<p>F. Piechatzek, Kran- u. Aufzug-Werke, Berlin N 65, Seestraße 51-56.</p> <p>Fernruf: 46 43 11. Drahtanschrift: Höferszug Gründung: 1890. Fabrikationsprogramm: Krane u. Aufzüge, Hebezeuge u. Hobemaschinen (Flaschenzüge, Laufkatzen, Winden, Elektro-Flaschenzüge). Geschäftsführer: Richard, Martin u. Paul Piechatzek. Prokuristen: Paul Gräning, Alfred Knop, Otto Kuhwald. Bankverbindung: Reichskredit-Gesellschaft A.-G., Berlin. Postcheck-Konto: 4847 Berlin. Geschäftsjahr: Kalenderjahr. Grundbesitz: 2600 qm, davon 2000 qm bebaut; gepachtet sind 1250 qm mit 700 qm bebauter Fläche. Anlagen: Verarbeitungs- u. Fabrikationsräume in Heidenheim u. München. Besondere Angaben: In München befindet sich ein Zweigwerk der Gesellschaft.</p>	<p>F. Piechatzek, Kran- u. Aufzug-Werke, Berlin N 65, Seestraße 51-56.</p> <p>Fernruf: 46 43 11. Drahtanschrift: Höferszug Gründung: 1890. Fabrikationsprogramm: Krane u. Aufzüge, Hebezeuge u. Hobemaschinen (Flaschenzüge, Laufkatzen, Winden, Elektro-Flaschenzüge). Geschäftsführer: Richard, Martin u. Paul Piechatzek. Prokuristen: Paul Gräning, Alfred Knop, Otto Kuhwald. Bankverbindung: Reichskredit-Gesellschaft A.-G., Berlin. Postcheck-Konto: 4847 Berlin. Geschäftsjahr: Kalenderjahr. Grundbesitz: 2600 qm, davon 2000 qm bebaut; gepachtet sind 1250 qm mit 700 qm bebauter Fläche. Anlagen: Verarbeitungs- u. Fabrikationsräume in Heidenheim u. München. Besondere Angaben: In München befindet sich ein Zweigwerk der Gesellschaft.</p>
<p>Eduard Pincuss Armaturenfabrik, Sanitäre Einrichtungen, Berlin O 17, Gr. Frankfurter Str. 13.</p> <p>Fernruf: 59 13 18. Drahtanschrift: epal Gründung: 1859. Fabrikationsprogramm: Wasserleitungs-Armaturen. Inhaber: Arthur Landsberger, Bln.-Charlottenburg; Ernst Reichenbach, Bln.-Grünewald. Prokuristen: Paul Derpsch, Frieda Thierschmann.</p>	<p>Eduard Pincuss Armaturenfabrik, Sanitäre Einrichtungen, Berlin O 17, Gr. Frankfurter Str. 13.</p> <p>Fernruf: 59 13 18. Drahtanschrift: epal Gründung: 1859. Fabrikationsprogramm: Wasserleitungs-Armaturen. Inhaber: Arthur Landsberger, Bln.-Charlottenburg; Ernst Reichenbach, Bln.-Grünewald. Prokuristen: Paul Derpsch, Frieda Thierschmann.</p>

1. Introduction & Digitalization

Research Question:

- Identification of changes in legal form of the listed companies
- Extraction of the **company name** and **legal forms** necessary

**Piccolo-Automaten G. m. b. H.,
Berlin W 35, Kurfürstenstraße 146.**
Fernruf: 21 20 95. **Drahtanschrift:** piccoloautomat
Gründung: 1932.
Fabrikationsprogramm: Schokoladen-Verkaufsapparate
(Tischautomaten, Kugelstechapparate).
Kapital: RM 20 000.—.
Anteileigner: Dr. Richard Schönthal, Wien.
Geschäftsführer: Erwin Hantsch, Bln.-Steglitz.
Bankverbindung: Deutsche Bank u. Disconto - Ges.,
Berlin.
Postscheck-Konto: 8012 Berlin.
Geschäftsjahr: 1./1.—31./12.
Anlagen: Mechanische Werkstätten.
Gefolgschaft: 13 Arbeiter u. 6 Angestellte.

1. Introduction & Digitalization

Research Question:

- Identification of changes in legal form of the listed companies
- Extraction of the **company name** and **legal forms** necessary

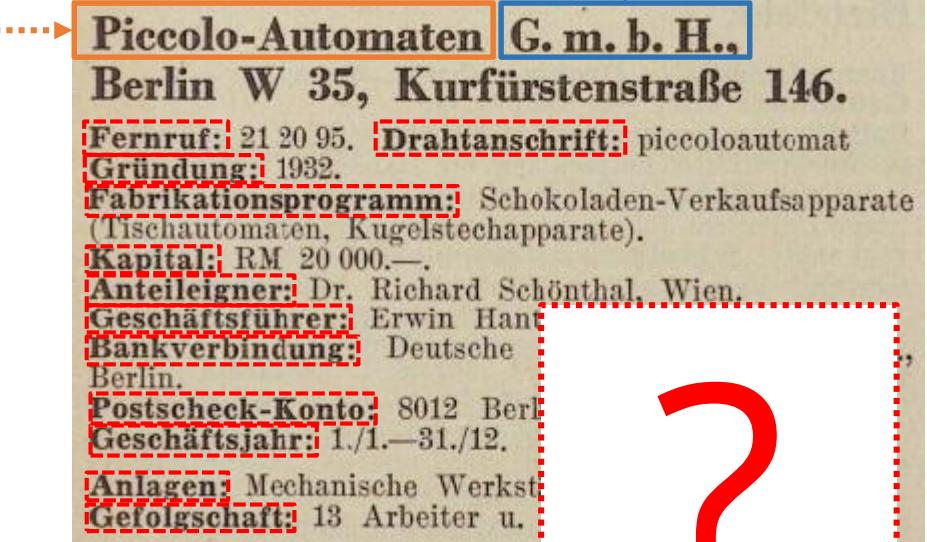


Piccolo-Automaten G. m. b. H.,
Berlin W 35, Kurfürstenstraße 146.
Fernruf: 21 20 95. **Drahtanschrift:** piccoloautomat
Gründung: 1932.
Fabrikationsprogramm: Schokoladen-Verkaufsapparate
(Tischautomaten, Kugelstechapparate).
Kapital: RM 20 000.—.
Anteileigner: Dr. Richard Schönthal, Wien.
Geschäftsführer: Erwin Hantsch, Bln.-Steglitz.
Bankverbindung: Deutsche Bank u. Disconto - Ges.,
Berlin.
Postscheck-Konto: 8012 Berlin.
Geschäftsjahr: 1./1.—31./12.
Anlagen: Mechanische Werkstätten.
Gefolgschaft: 13 Arbeiter u. 6 Angestellte.

1. Introduction & Digitalization

Research Question:

- Identification of changes in legal form of the listed companies
- Extraction of the **company name** and **legal forms** necessary



A historical document snippet with several fields highlighted by red dashed boxes. A large red question mark is placed in the bottom right corner of the document area.

Piccolo-Automaten G. m. b. H., Berlin W 35, Kurfürstenstraße 146.

Fernruf: 21 20 95. **Drahtanschrift:** piccoloautomat
Gründung: 1932.
Fabrikationsprogramm: Schokoladen-Verkaufsapparate (Tischautomaten, Kugelstechapparate).
Kapital: RM 20 000.—.
Anteilseigner: Dr. Richard Schönthal, Wien.
Geschäftsführer: Erwin Hane
Bankverbindung: Deutsche Bank Berlin.
Postcheck-Konto: 8012 Berlin
Geschäftsjahr: 1./1.—31./12.
Anlagen: Mechanische Werkst.
Gefolgschaft: 13 Arbeiter u.

1. Introduction & Digitalization

Approach and goal:

- Extract and structure data beyond the research question (realistic additional effort)
- Ensure reusability of the data for other research purposes
- Test workflow to gain experience for comparable projects



1. Introduction & Digitalization

Approach and goal:



Structured research data

Firmenname	Piccolo-Automaten
Rechtsform	G.m.b.H.
Sitz	Berlin W 35 Kurfürstenstraße 146
Fernruf	212095
Drahtanschrift	piccoloautomat
Gründung	1932
Produkt	Schokoladen- Verkaufsapparate (Tischautomaten, Kugelstechapparate)

...

1. Introduction & Digitalization

Challenges (text recognition):

- High quality requirements for research data
- Effort for OCR training difficult to estimate
- Layout (two columns → reading order)

<p>Phönix — Pincuss</p> <p>Phönix-Werk G. m. b. H., Spezialfabrik moderner Trocken- Apparate, Meerane (Sa.).</p> <p>Fernruf: 3234. Drahtanschrift: phönixwerk Gründung: 1907. Fabrikationsprogramm: Trockenapparate; Holzbearbeitungs-Maschinen. Kapital: RM 17 500.—. Anteilseigner: C. R. Nestmann, Meerane (100%). Geschäftsführer: Obering, A. Wackermann. Prokurist: J. Frenzel. Bankverbindungen: Meeraner Bank A.-G., Reichsbank, Meerane. Postcheck-Konto: 115 485 Leipzig. Geschäftsjahr: 1./1.—31./12. Grundbesitz: 3700 qm, davon 1462 qm bebaut. Anlagen: Fabrikationsräume mit Montagehalle, elektr. Schleißpresse, Kaufm. u. techn. Büro. Eigene Vertretungen: In Berlin: Willy Böckel, W 30, Martin-Luther-Str. 15.</p> <p>Besondere Angaben: Gegründet als Spezialfirma moderner Trocknungsanlagen. Hergestellt wurden Schlangenbündel-Trockenapparate System Otto und Getreide-trocknungsapparate. Zuletzt wurde ein anderes allgemeines Trocknungsprogramm. 1921 erfolgte die Übernahme durch die Gesellschaften der Fabrikation von Holzherbeutungsmaschinen. 1932 übernahm das Werk zusätzlich die Herstellung von Bewoid-Apparaturen für die Papierindustrie nach den Patenten Dr. Bruno Wiegner, Berlin.</p> <hr/> <p>Piccolo-Automaten G. m. b. H., Berlin W 35, Kurfürstenstraße 146.</p> <p>Fernruf: 21 20 05. Drahtanschrift: piccoloautomat Gründung: 1902. Fabrikationsprogramm: Schokoladen-Vorlaufapparate (Tischautomaten, Kugelstechapparate). Kapital: RM 20 000.—. Anteilseigner: Dr. Richard Schönthal, Wien. Geschäftsführer: Erwin Hantsch, Bln.-Steglitz. Bankverbindung: Deutsche Bank u. Disconto - Ges., Berlin. Postcheck-Konto: 8012 Berlin. Geschäftsjahr: 1./1.—31./12. Anlagen: Mechanische Werkstätten. Gefolgschaft: 13 Arbeiter u. 6 Angestellte.</p> <hr/> <p>F. Piechatzek, Kran- u. Aufzug-Werke, Berlin N 65, Seestraße 51-56.</p> <p>Fernruf: 46 43 11. Drahtanschrift: Höferszug Gründung: 1890. Fabrikationsprogramm: Krane u. Aufzüge, Hebezeuge u. Hobemaschinen (Flaschenzüge, Laufkatzen, Winden, Elektro-Flaschenzüge). Geschäftsführer: Richard, Martin u. Paul Piechatzek. Prokuristen: Paul Gräning, Alfred Knop, Otto Kuhwald. Bankverbindung: Reichskredit-Gesellschaft A.-G., Berlin. Postcheck-Konto: 4847 Berlin. Geschäftsjahr: Kalenderjahr. Grundbesitz: 2500 qm, davon 2000 qm bebaut; gepachtet sind 1200 qm mit 700 qm bebauter Fläche. Anlagen: Verarbeitungs- u. Fabrikationsräume in Heidenheim u. München. Besondere Angaben: In München befindet sich ein Zweigwerk der Gesellschaft.</p> <hr/> <p>Eduard Pincuss Armaturenfabrik, Sanitäre Einrichtungen, Berlin O 17, Gr. Frankfurter Str. 13.</p> <p>Fernruf: 59 13 18. Drahtanschrift: epal Gründung: 1859. Fabrikationsprogramm: Wasserleitungs-Armaturen. Inhaber: Arthur Landsberger, Bln.-Charlottenburg; Ernst Reichenbach, Bln.-Grünwald. Prokuristen: Paul Dorpsch, Frieda Thierschmann.</p>	<p>Otto Pieron siehe Maschinenfabrik</p> <hr/> <p>Paul Pietzschmann Wasserwerksbau, Berlin-Spandau, Schönwalder Str. 34.</p> <p>Fernruf: 37 68 71. Gründung: 1902. Fabrikationsprogramm: Entwurf und Bau von Trink- und Gebrauchswasserwerken jeder Größe. Entsiedlungsanlagen einschl. der erforderlichen Antriebsanlagen (Dampf — Diesel — Wasserkraft, Hoch- und Niederspannung). Inhaber: Ing. Paul Pietzschmann. Bankverbindungen: Dresdner Bank, Spandauer Bank, Spandau.</p> <p>Besondere Angaben: Der Firmeninhaber beschäftigt sich hauptsächlich mit der Erstellung halb- u. vollautomatisch arbeitender Wasserwerke u. besitzt hierüber große u. langjährige Erfahrungen.</p> <hr/> <p>Anton Piller Maschinenfabrik, Osterode (Harz), Abgunt 24.</p> <p>Fernruf: 211. Drahtanschrift: apo Gründung: 1900. Fabrikationsprogramm: Ventilatoren für Heizungs-, Lüftungs-, Absauge u. sonstige Zwecke. Bankverbindung: Reichsbank, Städt. Sparkasse, Osterode a. H. Postcheck-Konto: 40 278 Hannover.</p> <hr/> <p>Pilot. G. m. b. H. siehe Maschinenfabrik</p> <hr/> <p>Friedrich Piltz & Sohn K.-G., Heidenheim a. d. Brenz, Friedrichstr. 9.</p> <p>Fernruf: 637. Drahtanschrift: piltz Gründung: 1863. Fabrikationsprogramm: Genauigkeitswerkzeuge für Herstellung u. Kontrolle von Gewinden; Gewindeschleifmaschinen, Schleif- u. Schleif-Schleifer. Gesellschafter: Otto u. Walther Piltz. Geschäftsführer: Die Gesellschafter. Bankverbindungen: Reichsbank, Deutsche Bank u. Disconto-Ges., Heidenheim. Postcheck-Konto: 2178 Stuttgart. Geschäftsjahr: Kalenderjahr. Grundbesitz: 2600 qm, davon 2000 qm bebaut; gepachtet sind 1200 qm mit 700 qm bebauter Fläche. Anlagen: Verarbeitungs- u. Fabrikationsräume in Heidenheim u. München.</p> <p>Besondere Angaben: In München befindet sich ein Zweigwerk der Gesellschaft.</p> <hr/> <p>Eduard Pincuss Armaturenfabrik, Sanitäre Einrichtungen, Berlin O 17, Gr. Frankfurter Str. 13.</p> <p>Fernruf: 59 13 18. Drahtanschrift: epal Gründung: 1859. Fabrikationsprogramm: Wasserleitungs-Armaturen. Inhaber: Arthur Landsberger, Bln.-Charlottenburg; Ernst Reichenbach, Bln.-Grünwald. Prokuristen: Paul Dorpsch, Frieda Thierschmann.</p>
--	---

1. Introduction & Digitalization

Challenges (data structuring):

- No "all-in-one" solution available: Software must be written in-house
- High quality requirements for research data
- Profile separation
- Inconsistent attribute naming throughout the publication:
 - *Postscheck-Konto, Postschekkonto, Postcheck-Konto*
 - *Geschäftsführer, Geschäftsleiter, Direktor, Betriebsführer*
 - ...

<p>Phönix — Pincuss</p> <p>Phönix-Werk G. m. b. H., Spezialfabrik moderner Trocken- Apparate, Meerane (Sa.).</p> <p>Fernruf: 3294. Drahtanschrift: phönixwerk Gründung: 1907. Fabrikationsprogramm: Trockenapparate; Holzbearbeitungs-Maschinen. Kapital: RM 17 500.—. Anteilseigner: C. R. Nestmann, Meerane (100%). Geschäftsführer: Obering, A. Wackermann. Prokurist: J. Frenzel. Bankverbindungen: Meeraner Bank A.-G., Reichsbank, Meerane. Postcheck-Konto: 115 485 Leipzig. Geschäftsjahr: 1./I.—31./I2.</p> <p>Grundbesitz: 3700 qm, davon 1462 qm bebaut. Anlagen: Fabrikationsräume mit Montagehalle, elektr. Schleißpresse, Zellerei, u. anderes. Eigene Vertretungen: In Berlin: Willy Böckel, W 30, Martin Luther Str. 15.</p> <p>Besondere Angaben: Gegründet als Spezialfirma moderner Trocknungsanlagen. Hergestellt wurden Schlangenbündel-Trockenapparate System Otto und Getreide-trocknungsapparate. 1921 erfolgte nach dem Erwerb der Trocknungsanlagen 1921 die Aufnahme der Fabrikation von Holzbehandlungs-maschinen. 1922 übernahm das Werk zusätzlich die Herstellung von Bewoid-Apparaturen für die Papierindustrie nach den Patenten Dr. Bruno Wiegner, Berlin.</p> <hr/> <p>Piccolo-Automaten G. m. b. H., Berlin W 35, Kurfürstenstraße 146.</p> <p>Fernruf: 21 20 05. Drahtanschrift: piccoloautomat Gründung: 1902. Fabrikationsprogramm: Schokoladen-Vorlaufapparate (Tischautomaten, Kugelstechapparate). Kapital: RM 20 000.—. Anteilseigner: Dr. Richard Schönthal, Wien. Geschäftsführer: Erwin Hantsch, Bln-Steglitz. Bankverbindung: Deutsche Bank u. Disconto-Ges., Berlin. Postcheck-Konto: 8012 Berlin. Geschäftsjahr: 1./I.—31./I2. Anlagen: Mechanische Werkstätten. Gefolgschaft: 13 Arbeiter u. 6 Angestellte.</p> <hr/> <p>F. Piechatzek, Kran- u. Aufzug-Werke, Berlin N 65, Seestraße 51-56.</p> <p>Fernruf: 46 43 11. Drahtanschrift: Höferszug Gründung: 1892. Fabrikationsprogramm: Krane u. Aufzüge, Hebezeuge u. Hobemaschinen (Flaschenzüge, Laufkatzen, Winden, Elektro-Flaschenzüge). Geschäftsführer: Richard, Martin u. Paul Piechatzek. Prokuristen: Paul Gräning, Alfred Knop, Otto Kuhwald. Bankverbindung: Reichskredit-Gesellschaft A.-G., Berlin. Postcheck-Konto: 4847 Berlin. Geschäftsjahr: Kalenderjahr. Grundbesitz: 9500 qm, davon 4500 qm bebaut; gepachtet sind 1250 qm mit 700 qm bebauter Fläche. Anlagen: Ventilations- u. Fabrikationsräume in Heidenheim u. München. Besondere Angaben: In München befindet sich ein Zweigwerk der Gesellschaft.</p> <hr/> <p>Eduard Pincuss Armaturenfabrik, Sanitäre Einrichtungen, Berlin O 17, Gr. Frankfurter Str. 13.</p> <p>Fernruf: 59 13 18. Drahtanschrift: epal Gründung: 1859. Fabrikationsprogramm: Wasserleitungs-Armaturen. Inhaber: Arthur Landsberger, Bln-Charlottenburg; Ernst Reichenbach, Bln-Grünewald. Prokuristen: Paul Dörpsch, Frieda Thierschmann.</p>	<p>Otto Pieron siehe Maschinenfabrik</p> <hr/> <p>Paul Pietzschmann Wasserwerksbau, Berlin-Spandau, Schönwalder Str. 34.</p> <p>Fernruf: 37 68 71. Gründung: 1902. Fabrikationsprogramm: Entwurf und Bau von Trink- und Gebrauchswasserwerken jeder Größe. Entsiedlungs-anlagen einschl. der erforderlichen Antriebsanlagen (Dampf — Diesel — Wasserkraft, Hoch- und Niederspannung). Inhaber: Ing. Paul Pietzschmann. Bankverbindungen: Dresdner Bank, Spandauer Bank, Spandauer Bank. Besondere Angaben: Der Firmeninhaber beschäftigt sich hauptsächlich mit der Erstellung halb- u. vollauto-matisch arbeitender Wasserwerke u. besitzt hierüber große u. langjährige Erfahrungen.</p> <hr/> <p>Anton Piller Maschinenfabrik, Osterode (Harz), Abgunt 24.</p> <p>Fernruf: 211. Drahtanschrift: apo Gründung: 1900. Fabrikationsprogramm: Ventilatoren für Heizungs-, Lüftungs-, Absauge u. sonstige Zwecke. Bankverbindung: Reichsbank, Städt. Sparkasse, Oste-rod a. H. Postcheck-Konto: 40 278 Hannover.</p> <hr/> <p>Pilot. G. m. b. H. siehe Maschinenfabrik</p> <hr/> <p>Friedrich Piltz & Sohn K.-G., Heidenheim a. d. Brenz, Friedrichstr. 9.</p> <p>Fernruf: 637. Drahtanschrift: piltz Gründung: 1863. Fabrikationsprogramm: Genauigkeitswerkzeuge für Herstellung u. Kontrolle von Gewinden; Gewindeschliffmaschinen, Schleif- u. Fräsmaschinen. Gesellschafter: Otto u. Walther Piltz. Geschäftsführer: Die Gesellschafter. Bankverbindungen: Reichsbank, Deutsche Bank u. Dis-conto-Ges., Heidenheim. Postcheck-Konto: 2178 Stuttgart. Geschäftsjahr: Kalenderjahr. Grundbesitz: 2600 qm, davon 2000 qm bebaut; gepachtet sind 1250 qm mit 700 qm bebauter Fläche. Anlagen: Ventilations- u. Fabrikationsräume in Heidenheim u. München.</p> <hr/> <p>Besondere Angaben: In München befindet sich ein Zweigwerk der Gesellschaft.</p> <hr/> <p>Eduard Pincuss Armaturenfabrik, Sanitäre Einrichtungen, Berlin O 17, Gr. Frankfurter Str. 13.</p> <p>Fernruf: 59 13 18. Drahtanschrift: epal Gründung: 1859. Fabrikationsprogramm: Wasserleitungs-Armaturen. Inhaber: Arthur Landsberger, Bln-Charlottenburg; Ernst Reichenbach, Bln-Grünewald. Prokuristen: Paul Dörpsch, Frieda Thierschmann.</p>
---	--

1. Introduction & Digitalization

Challenges (Infrastructure, staff):

- Multi-part workflow with specific infrastructural and staff requirements
- Digitization (1 project coordinator, 1 research assistant)
- OCR (1 project coordinator, 1 developer)
- Data structuring (1 developer)
- OCR server (eScriptorium)

Phönix — Pincuss

Phönix-Werk G. m. b. H., Spezialfabrik moderner Trocken- Apparate, Meerane (Sa.).

Fernruf: 3234. Drahtanschrift: phönixwerk
Gründung: 1907.
Fabrikationsprogramm: Trockenapparate; Holzbearbeitungs-Maschinen.
Kapital: RM 17 500.—.
Anteilseigner: C. R. Nestmann, Meerane (100%).
Geschäftsführer: Obering, A. Wackermann.
Prokurist: J. Frenzel.
Bankverbindungen: Meeraner Bank A.-G., Reichsbank, Meerane.
Postcheck-Konto: 115 485 Leipzig.
Geschäftsjahr: 1./1.—31./12.

Grundbesitz: 3700 qm, davon 1462 qm bebaut.
Anlagen: Fabrikationsräume mit Montagehalle, elektr. Schleißerei, Zellerei, u. anderes.
Eigene Vertretungen: In Berlin: Willy Böckel, W 30, Martin-Luther-Str. 15.
Besondere Angaben: Gegründet als Spezialfirma moderner Trocknungsanlagen. Hergestellt wurden Schlangenbündel-Trockenapparate System Otto und Getreide-trockenapparate. Zuletzt wurden andere allgemeine Trocknungsanlagen. 1921 erfolgte nach dem Erwerb der Fabrikation von Holzbearbeitungs-maschinen. 1922 übernahm das Werk zusätzlich die Herstellung von Bewoid-Apparaturen für die Papierindustrie nach den Patenten Dr. Bruno Wiegner, Berlin.

Piccolo-Automaten G. m. b. H., Berlin W 35, Kurfürstenstraße 146.

Fernruf: 21 20 05. Drahtanschrift: piccoloautomat
Gründung: 1902.
Fabrikationsprogramm: Schokoladen-Vorlauftypen (Tischautomaten, Kugelstechapparate).
Kapital: RM 20 000.—.
Anteilseigner: Dr. Richard Schönthal, Wien.
Geschäftsführer: Erwin Hantsch, Bln.-Steglitz.
Bankverbindung: Deutsche Bank u. Disconto-Ges., Berlin.
Postcheck-Konto: 8012 Berlin.
Geschäftsjahr: 1./1.—31./12.
Anlagen: Mechanische Werkstätten.
Gefolgschaft: 13 Arbeiter u. 6 Angestellte.

F. Piechatzek, Kran- u. Aufzug-Werke, Berlin N 65, Seestraße 51-56.

Fernruf: 46 43 11. Drahtanschrift: Höferszug
Gründung: 1892.
Fabrikationsprogramm: Krane u. Aufzüge, Hebezeuge u. Hobemaschinen (Flaschenzüge, Laufkatzen, Winden, Elektro-Flaschenzüge).
Geschäftsführer: Richard, Martin u. Paul Piechatzek.
Prokuristen: Paul Gräning, Alfred Knop, Otto Kuhwald.
Bankverbindung: Reichskredit-Gesellschaft A.-G., Berlin.
Postcheck-Konto: 4847 Berlin.
Geschäftsjahr: Kalenderjahr.

Grundbesitz: 9500 qm, davon 4500 qm bebaut.
Anlagen: Maschinenbau-Werkstätten (Dreherei, Schleiferei, Fräserei, Presserei u. Schlosserei).
Eigene Vertretungen: Im Ausland.
Besondere Angaben: Der Export erstreckt sich auf alle Weltteile.
Gefolgschaft: 350 Mitglieder.

Otto Pieron
siehe Maschinenfabrik

Paul Pietzschmann Wasserwerksbau, Berlin-Spandau, Schönwalder Str. 34.

Fernruf: 37 68 71.
Gründung: 1923.
Fabrikationsprogramm: Entwurf und Bau von Trink- und Gebrauchswasserwerken jeder Größe. Entsiedlungs-anlagen einschl. der erforderlichen Antriebsanlagen (Dampf — Diesel — Wasserkraft, Hoch- und Niederspannung).
Inhaber: Ing. Paul Pietzschmann.
Bankverbindungen: Dresdner Bank, Spandauer Bank, Spandau.

Besondere Angaben: Der Firmeninhaber beschäftigt sich hauptsächlich mit der Erstellung halb- u. vollauto-matisch arbeitender Wasserwerke u. besitzt hierüber große u. langjährige Erfahrungen.

Anton Piller Maschinenfabrik, Osterode (Harz), Abgunt 24.

Fernruf: 211. Drahtanschrift: apo
Gründung: 1909.
Fabrikationsprogramm: Ventilatoren für Heizungs-, Lüftungs-, Absaug- u. sonstige Zwecke.
Bankverbindung: Reichsbank, Städt. Sparkasse, Oste-rode a. H.
Postcheck-Konto: 40 278 Hannover.

Pilot. G. m. b. H.
siehe Maschinenfabrik

Friedrich Piltz & Sohn K.-G., Heidenheim a. d. Brenz, Friedrichstr. 9.

Fernruf: 637. Drahtanschrift: piltz
Gründung: 1863.
Fabrikationsprogramm: Genauigkeitswerkzeuge für Herstellung u. Kontrolle von Gewinden; Gewindeschliff- und Spannschraubmaschinen, Schleifmaschinen.
Gesellschafter: Otto u. Walther Piltz.
Geschäftsführer: Die Gesellschafter.
Bankverbindungen: Reichsbank, Deutsche Bank u. Dis-conto-Ges., Heidenheim.
Postcheck-Konto: 2178 Stuttgart.
Geschäftsjahr: Kalenderjahr.

Grundbesitz: 2600 qm, davon 2000 qm bebaut; gepachtet sind 1250 qm mit 700 qm bebauter Fläche.
Anlagen: Ventilatoren- u. Fabrikationsräume in Heidenheim u. München.

Besondere Angaben: In München befindet sich ein Zweigwerk der Gesellschaft.

Eduard Pincuss Armaturenfabrik, Sanitäre Einrichtungen, Berlin O 17, Gr. Frankfurter Str. 13.

Fernruf: 59 13 18. Drahtanschrift: epal
Gründung: 1859.
Fabrikationsprogramm: Wasserleitungs-Armaturen.
Inhaber: Arthur Landsberger, Bln.-Charlottenburg; Ernst Reichenbach, Bln.-Grunewald.
Prokuristen: Paul Dorpsch, Frieda Thierschmann.

2. Layout segmentation and OCR via eScriptorium

Alle Inhalte dieser Präsentation stehen unter der [Lizenz Creative Commons BY 4.0 International](#), sofern nicht anders angegeben.



2. Layout segmentation and OCR via eScriptorium

eScriptorium

Transcription software

Open source platform for manual or automated segmentation and text recognition of historical manuscripts and prints.



Developer:	PSL (Paris)
Year of release:	2018
Current version:	0.10.5 (2022)
Operating system:	platform independent
Programming Lang.:	Python, JavaScript, Hypertext Markup Language
OCR engine:	Kraken
License:	MIT license
Models:	https://ub-backup.bib.uni-mannheim.de/~stweil/eScriptorium/ (Fraktur)
Additional info:	https://ocr-bw.bib.uni-mannheim.de/tag/escriptorium/

2. Layout segmentation and OCR via eScriptorium

Kraken

OCR engine for layout segmentation and text recognition

Kraken is an all-in-one open source OCR software solution optimized for historical documents and non-Latin writing systems, with fully trainable layout analysis and text recognition.

Developer: Benjamin Kiessling

Year of release: 2015

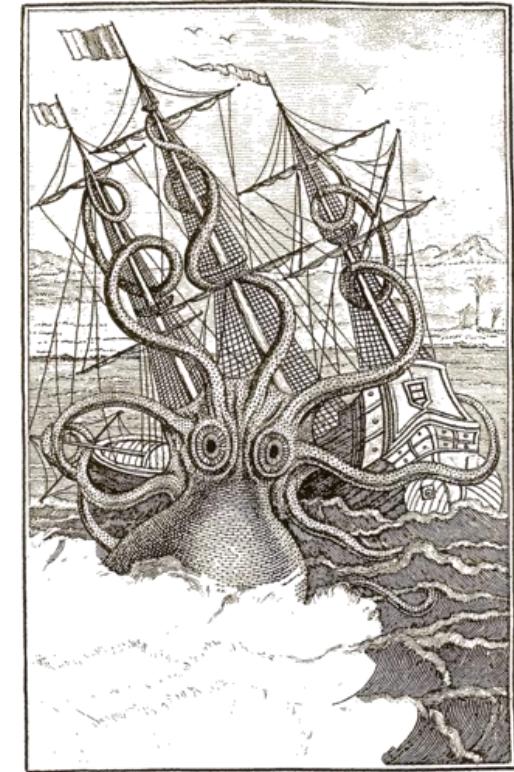
OCR technology: bounding box and baseline-based (eScriptorium)

Export formats: ALTO, PageXML, abbyyXML and hOCR

Programming lang.: Python

Models: <https://ub-backup.bib.uni-mannheim.de/~stweil/eScriptorium/> (Fraktur)

License : MIT License



Workflow eScriptorium

Layout segmentation and text recognition

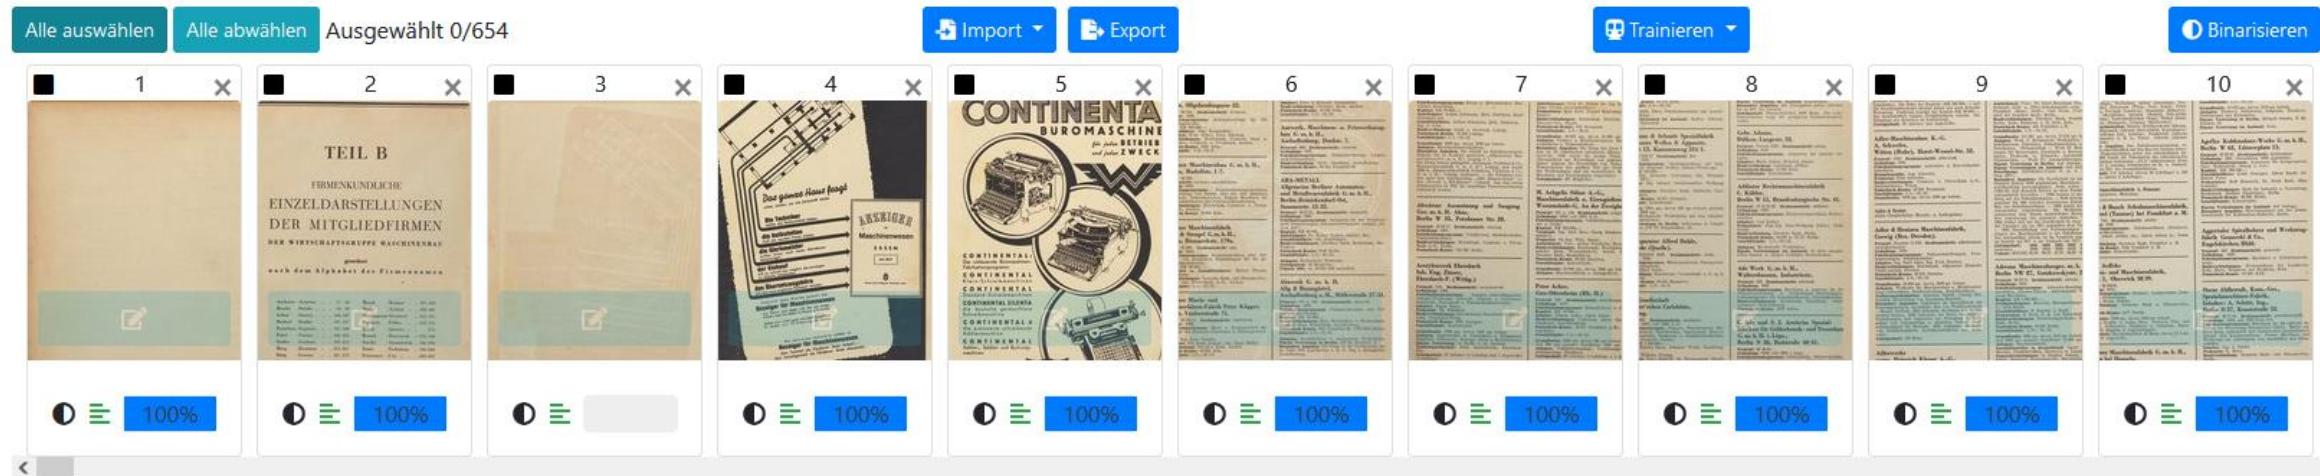
1. Upload of the digitized files
2. Selection of a suitable base model for layout segmentation and text recognition
3. Identification of weak points of the models
4. Creation of ground truth
5. Work-specific training of the models
6. Layout segmentation and text recognition

If no base model can be found, another system should be used or a "from-scratch" model has to be trained (much higher training effort)

2. Layout segmentation and OCR via eScriptorium

Upload of the digitized files

Digitized files can be uploaded via the GUI or the API individually or in a batch



Overview of all 654 images in the newly created project

Layout segmentation

Alle Inhalte dieser Präsentation stehen unter der [Lizenz Creative Commons BY 4.0 International](#), sofern nicht anders angegeben.

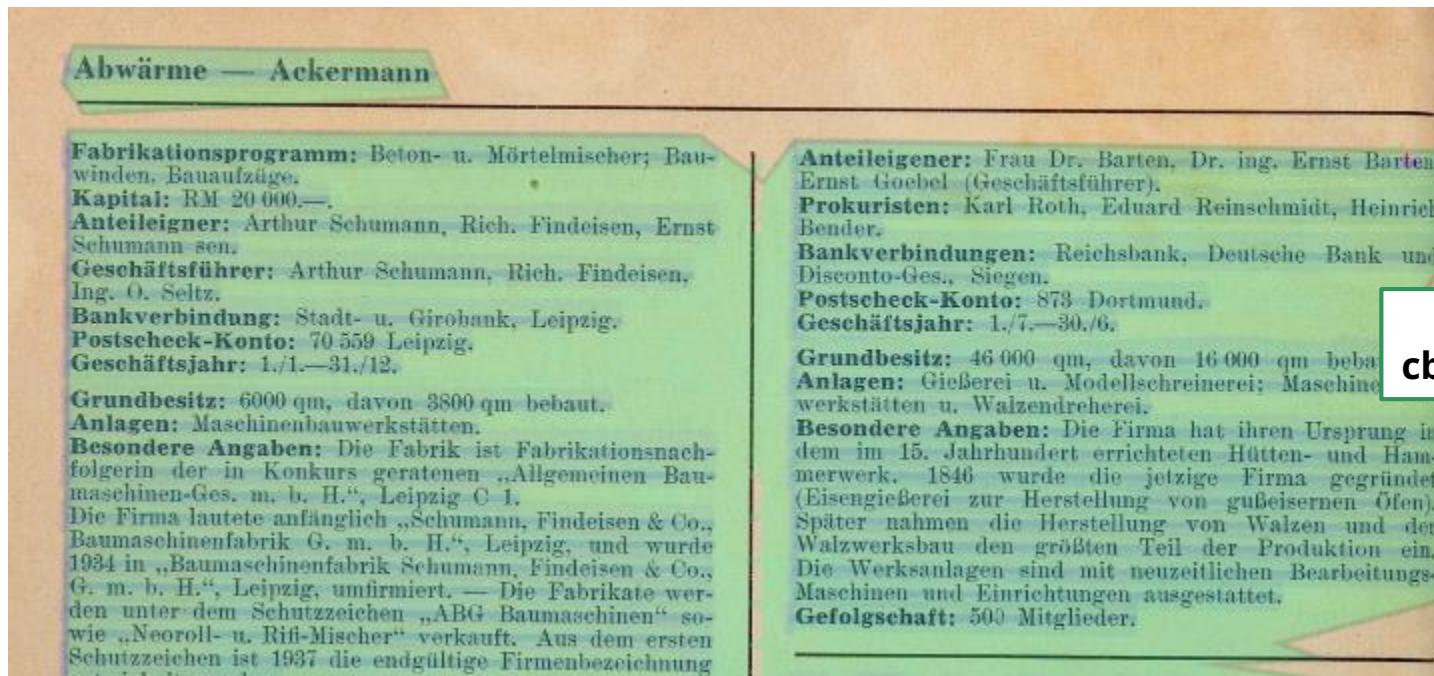


2. Layout segmentation and OCR via eScriptorium

Selection of a suitable base model

Segmentation consists of two steps:

1. Segmentation of text regions
2. Segmentation of text lines (baseline and polygons)



2. Layout segmentation and OCR via eScriptorium



BERD@NFDI

Weakness: profile segmentation

Segmentation with cbad_1800

Abwärme — Ackermann

Fabrikationsprogramm: Beton- u. Mörtelmischer; Bau-Kapital: RM 20 000,—
Anteiligeren: Arthur Schumann, Rich. Findeisen, Ernst Bender
Geschäftsführer: Arthur Schumann, Rich. Findeisen; Ing. O. Soltz
Postcheck-Konto: Stadt- u. Girobank, Leipzig
Geschäftsjahr: 1./1.—31./12.

Grundbesitz: 46 000 qm, davon 38 000 qm bebaut;
Anlagen: Gießerei u. Modellgießerei; Maschinenbauwerkstätten u. Walzenfabrik.
Besondere Angaben: Die Firma ist Fabrikationszulieferer der im Konkurs geratenen „Allgemeinen Bau und Industrie“ in Berlin-Lichtenberg. Leipzig, und wurde 1894 in „Baumaschinenfabrik Schumann, Findeisen & Co.“ gegründet. Die Fabrikate werden unter dem Schutzzeichen „ABO-Baumaschinen“ wie „Neosil- u. Rö-Mischer“ verkauft. Aus dem ersten Schutzzeichen ist 1907 die endgültige Firmenbezeichnung entstanden.

M. Achgelis Söhne A.-G.,
Maschinenfabrik u. Eisengießerei,
Wesermünde-G, An der Zweighahn 1.

Fernruf: 101 u. 140. **Drahtanschrift:** achgeliswerke
Gründung: 1883. **Umsatz:** 4998 A.-G.
Fabrikationsprogramm: Schleißhalmsechsen in jeder Art u. Größe
Kapital: RM 225 000.—
Prokurist: Dr. Ing. Karl Boos, Georg Brinkmann, Wesermünde.
Aufsichtsrat: Vors. Arthur Friedrichs, Bremerhaven.
Inhaber: Johann Acker, Jakob Acker, Wesermünde; Gesellschafter: Bank, Wesermünde-G.; Nordd. Kreditbank, Dresden; Bank, Bremerhaven.
Bankverbindungen: Gewerbebank, Ebersbach/F.; Reichsbank, Stuttgart; Commerz- u. Privatbank, Berlin.
Postcheck-Konto: 118 120 - Berlin.
Geschäftsjahr: Kalenderjahr.

Grundbesitz: 18 500 qm, davon 12 000 qm bebaut;
Anlagen: Maschinenfabrik u. Eisengießerei.

Peter Acker,
Gau-Oderheim (Rh. H.)

Fernruf: 220. **Drahtanschrift:** maschinacker
Gründung: 1878. **Umsatz:** 1000 A.-G.
Fabrikationsprogramm: Hobelförderer u. Pflege,
Inhaber: Eugen Zlaser.
Prokurist: Dr. Friedrich Bäck, Ebersbach-Gewerbebank, Ebersbach/F.; Reichsbank, Göttingen-Wilhelmshaven.
Postcheck-Konto: 25 571 - Frankfurt a/M.; 9617 - Ludwigshafen.
Geschäftsjahr: 1./1.—31./12.

Grundbesitz: 1200 qm, davon 800 qm bebaut; gehalten sind 300 qm gesamte Nutzfläche; 1500 qm Anlagen, Montageanlage, Vorführungs- u. Ausstellungsräume, Tiefgarage.
Gefolgschaft: 20 Arbeiter (1 Lehrling) und 7 Angestellte (1 Lehrling).

Achenbach Söhne G.m.b.H.,
Buschhütten (Kr. Siegen).

Fernruf: Siegen 5011. **Drahtanschrift:** achenbachsöhne
Gründung: 1884. **Umsatz:** 1000 A.-G.
Fabrikationsprogramm: Walzwerkshallen- und Walzen-
Kapital: RM 1.554 000.—

Optimal segmentation

Abwärme — Ackermann

Fabrikationsprogramm: Beton- u. Mörtelmischer; Bau-Kapital: RM 20 000.—
Anteiligeren: Arthur Schumann, Rich. Findeisen, Ernst Bender
Geschäftsführer: Arthur Schumann, Rich. Findeisen; Ing. O. Soltz
Bankverbindungen: Reichsbank, Deutsche Bank und Disconto-Ges., Siegen
Postcheck-Konto: 70 260 - Leipzig, Dortmund
Geschäftsjahr: 1./1.—31./12.

Grundbesitz: 6000 qm, davon 3800 qm bebaut;
Anlagen: Maschinenbauwerkstätten, Walzenfabrik.
Besondere Angaben: Die Firma hat ihren Ursprung in dem im 15. Jahrhundert errichteten Hütten- und Hämmerwerk. 1846 wurde die jetzige Firma gegründet (Eisengießerei zur Herstellung von gusseisernen Ofen). Die Firma lautete ursprünglich „Schumann, Findeisen & Co.“, später „Achgelis, Schumann, Findeisen & Co.“. Später nahmen die Herstellung von Walzen und der Walzwerken den größten Teil der Produktion ein. Die Werkstätten sind mit mechanischen Bearbeitungs-Maschinen und Einrichtungen ausgestattet.
Gefolgschaft: 563 Mitglieder.

M. Achgelis Söhne A.-G.,
Maschinenfabrik u. Eisengießerei,
Wesermünde-G, An der Zweighahn 1.

Fernruf: 101 u. 140. **Drahtanschrift:** achgeliswerke
Gründung: 1883. **Umsatz:** A.-G.
Fabrikationsprogramm: Schleißhalmsechsen in jeder Art u. Größe
Kapital: RM 225 000.—
Vorstand: Ing. Karl Boos, Georg Brinkmann, Wesermünde.
Prokurist: Ob.-Ing. Willi Barth.
Aufsichtsrat: Vors. Arthur Friedrichs, Bremerhaven.
Inhaber: Johann Acker, Jakob Acker, Wesermünde; Gesellschafter: Bank, Wesermünde-G.; Nordd. Kreditbank, Dresden; Bank, Bremerhaven.
Bankverbindungen: Reichsbank, Commerz- u. Privatbank, Berlin.
Postcheck-Konto: 118 120 - Berlin.
Geschäftsjahr: Kalenderjahr.

Acetylenwerk Ebersbach
Inh. Eug. Zinser,
Ebersbach-F. (Wtbg.)

Fernruf: 210. **Drahtanschrift:** acetylwerk
Gründung: 1888.
Fabrikationsprogramm: Autogen-Schweißapparate; Automobil-Schweiß-, Schleife-, Schneids- u. Lötbrenner, Gasrohre, Wasserstoff u. Drosseln-Reduzierventile.
Inhaber: Eugen Zinser.
Prokurist: Th. Friedrichs.
Bankverbindungen: Gewerbebank, Ebersbach/F.; Reichsbank, Stuttgart; Commerz- u. Privatbank, Stuttgart.
Postcheck-Konto: 5228 - Stuttgart.
Geschäftsjahr: Kalenderjahr.

Peter Acker,
Gau-Oderheim (Rh. H.)

Fernruf: 220. **Drahtanschrift:** maschinacker
Gründung: 1878. **Umsatz:** 1000 A.-G.
Fabrikationsprogramm: Hobelförderer u. Pflege,
Inhaber: Eugen Zlaser.
Prokurist: Dr. Friedrich Bäck, Ebersbach-Gewerbebank, Ebersbach/F.; Reichsbank, Göttingen-Wilhelmshaven.
Postcheck-Konto: 2288 - Stuttgart.
Geschäftsjahr: Kalenderjahr.

Grundbesitz: 1200 qm, davon 1200 qm bebaut;
Anlagen: Montagehalle, Schweißerei u. Klempnerei, Schleifer, Schlosserei, Montage, Eisen- u. Metallbearbeitung, Montageanlage, Vorführungs- u. Ausstellungsräume, Tiefgarage.
Gefolgschaft: 70 Arbeiter (1 Lehrling) und 7 Angestellte (1 Lehrling).

Achenbach Söhne G.m.b.H.,
Buschhütten (Kr. Siegen).

Fernruf: Siegen 5011. **Drahtanschrift:** achenbachsöhne
Gründung: 1884. **Umsatz:** 1000 A.-G.
Fabrikationsprogramm: Walzwerkshallen- und Walzen-
Kapital: RM 1.554 000.—

Weakness: text lines

When recognizing text lines, the baseline is not always correct and sometimes lines are divided into small parts

Anlagen: Maschinen-, Werkzeugfabrik u. Kaltwalzwerk.						
Gefolgschaft:	1930/31	31/32	32/33	33/34	34/35	35/36
Arbeiter	137	87	96	102	108	109
Angestellte	16	15	15	16	17	17
Umsatz (Mill RM)	1,1	0,9	0,7	0,85	0,85	0,9

Example: Text line segmentation of a table

Work-specific training

- Ground truth:** 47 pages
Result: Recognition of text regions unsatisfactory (solution: usage of a different pre- and post-processing workflow)
Results (text lines): Significant improvement

Anlagen: Maschinen-, Werkzeugfabrik u. Kaltwalzwerk.						
Gefolgschaft: 1930/31 31/32 32/33 33/34 34/35 35/36						
cbad_1800	Arbeiter	137	87	96	102	108
cbad_1800_trained	Angestellte	16	15	15	16	17
	Umsatz (Mill RM)	1,1	0,9	0,7	0,85	0,85

Anlagen: Maschinen-, Werkzeugfabrik u. Kaltwalzwerk.						
Gefolgschaft: 1930/31 31/32 32/33 33/34 34/35 35/36						
cbad_1800	Arbeiter	137	87	96	102	108
cbad_1800_trained	Angestellte	16	15	15	16	17
	Umsatz (Mill RM)	1,1	0,9	0,7	0,85	0,85

OCR

Alle Inhalte dieser Präsentation stehen unter der [Lizenz Creative Commons BY 4.0 International](#), sofern nicht anders angegeben.



OCR: Selection of a suitable base model

A suitable base model should:

- 1) cover the character set of the source material (if possible)
- 2) have already good recognition rates on the material in question

Suitable OCR model: digitue



2. Layout segmentation and OCR via eScriptorium

Weaknesses in text recognition

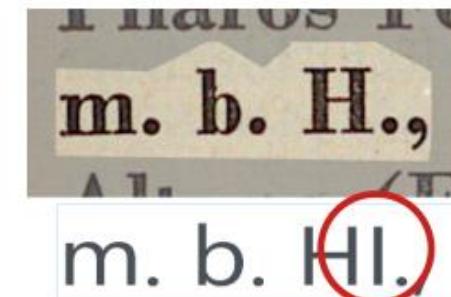
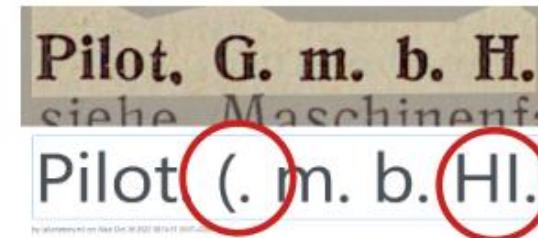
The model already delivers very good results with text recognition rates > 98%

Some specific errors can be identified:

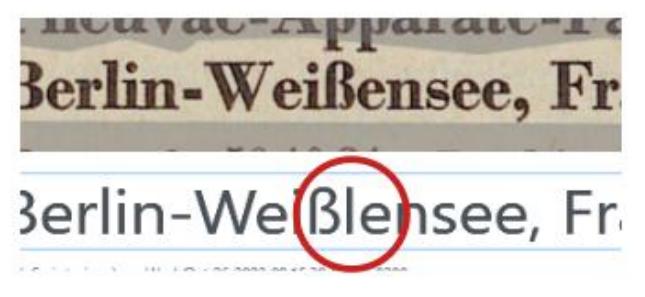
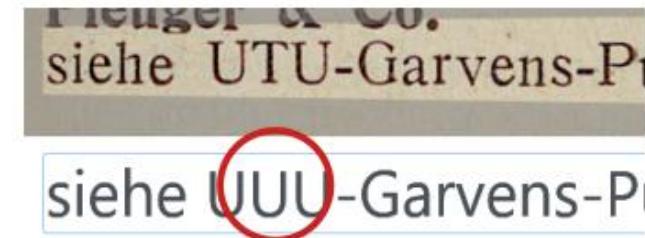
Percent sign



String „G.m.b.H.“



rare characters /
character combinations

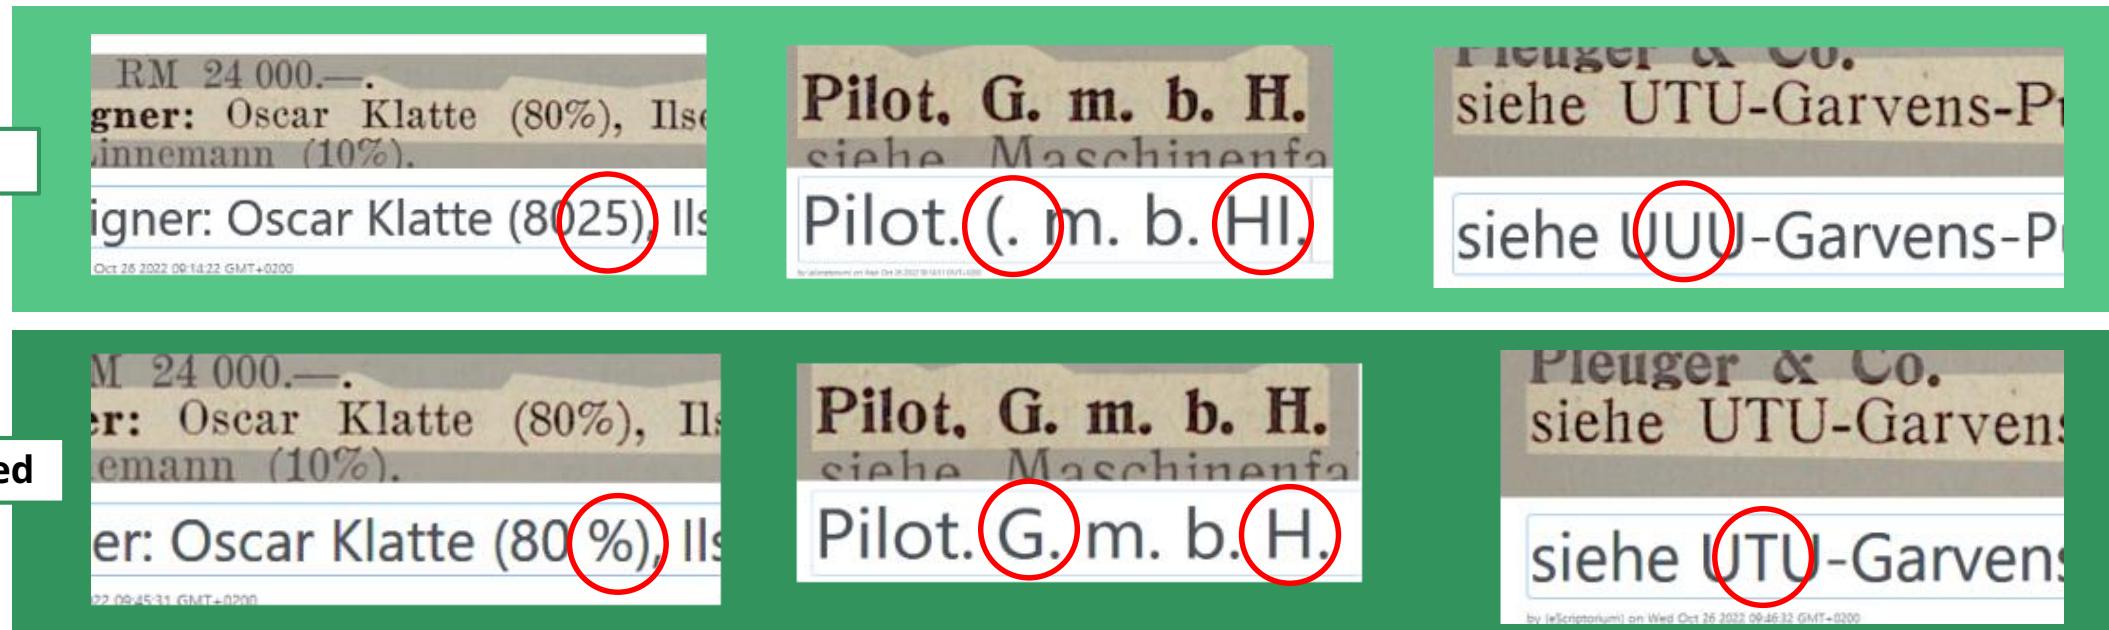


2. Layout segmentation and OCR via eScriptorium

Work-specific training

Ground truth: 26 pages

Results text recognition: CER could be improved to > 99.85 %

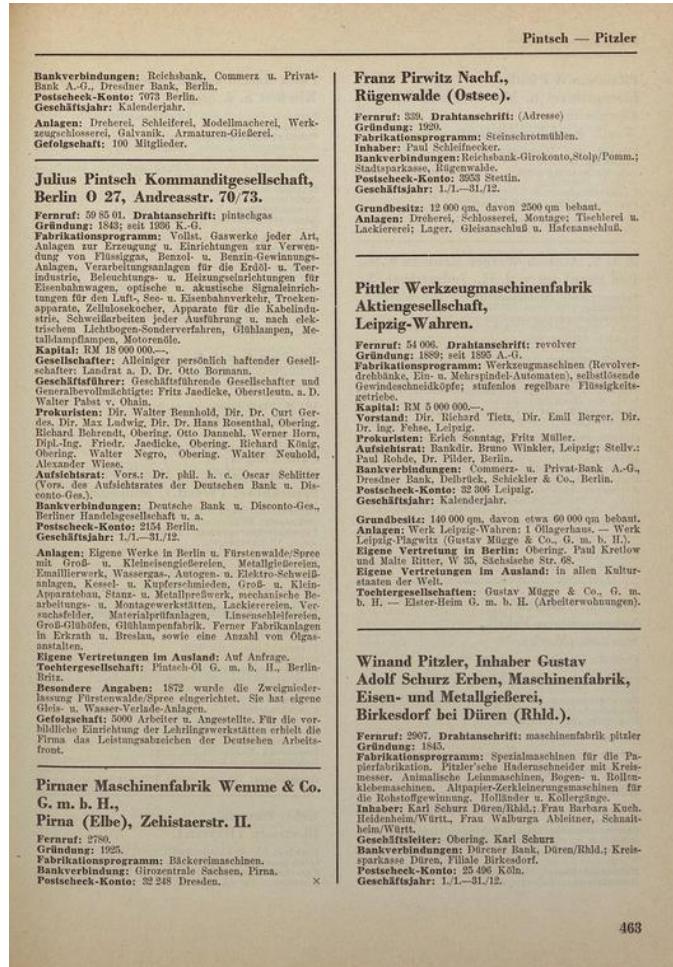


3. Extraction and Structuring via Python

Alle Inhalte dieser Präsentation stehen unter der [Lizenz Creative Commons BY 4.0 International](#), sofern nicht anders angegeben.



3. Extraction and Structuring via Python: Input data



```

1  <?xml version="1.0" encoding="UTF-8" standalone="yes"?>
2  <PcGts xmlns="http://schema.primaresearch.org/PAGE/gts/pagecontent/2019-07-15" xmlns
3   xsi:schemaLocation="http://schema.primaresearch.org/PAGE/gts/pagecontent/2019-07-15
4   http://schema.primaresearch.org/PAGE/gts/pagecontent/2019-07-15/pagecontent.xsd">
5
6   <Metadata>
7     <Creator>escriptorium</Creator>
8     <Created>2022-09-19T12:10:54.541269+00:00</Created>
9     <LastChange>2022-09-19T12:10:54.541290+00:00</LastChange>
10
11   </Metadata>
12   <Page imagefilename="maschinenindustrie_1937_0452.jpg" imageWidth="2796" imageHeight="1500" page="1" pageWidth="2796" pageHeight="1500" rotation="0">
13     <TextRegion id="r_2_1" >
14       <Coords points="127,354 1290,354 1290,685 127,685"/>
15
16     <TextLine id="eSc_line_835f5cf" >
17       <Coords points="1269,350 1148,348 1132,348 1109,348 1086,348 1063,348 880,348 857,348 834,348 825,350 818,350 815,350 811,348 811,348 788,348 765,348 673,348 650,348 632,348 627,348 605,348 582,348 559,348 536,348 513,348 490,348 307,348 284,348 261,348 238,348 215,348 192,348 169,348 146,348 144,345 126,348 126,382 1292,387"/>
18
19     <TextEquiv>
20       <Unicode>Bankverbindungen: Reichsbank, Commerz u. Privat-Bank A.-G., Dresdner Bank, Dehrtrek, Schleiferl & Co., Berlin.  

21     </TextEquiv>
22   </TextLine>
23
24
25
26     <TextLine id="eSc_line_eff01337" >
27       <Coords points="128,426 126,449 877,449 880,430 877,396 128,389 128,426"/>
28       <Baseline points="128,426 880,430"/>
29     <TextEquiv>
30       <Unicode>Bank A.-G., Dresdner Bank, Berlin.</Unicode>
31     </TextEquiv>
32   </TextLine>

```

PAGE-XML

Is PAGE-XML
enough to
answer the
research
question?

3. Extraction and Structuring via Python: blatt

Blatt

pypi package 0.1.6

NLP-helper for OCR-ed pages in [PAGE XML](#) format.

***Blatt* functions:**

1. reads PAGE-XML
2. removes hyphens
3. converts PAGE-XML to TXT and TSV formats
4. provides module for data structuring

Installation

```
pip install blatt
```

Open Source + CLI



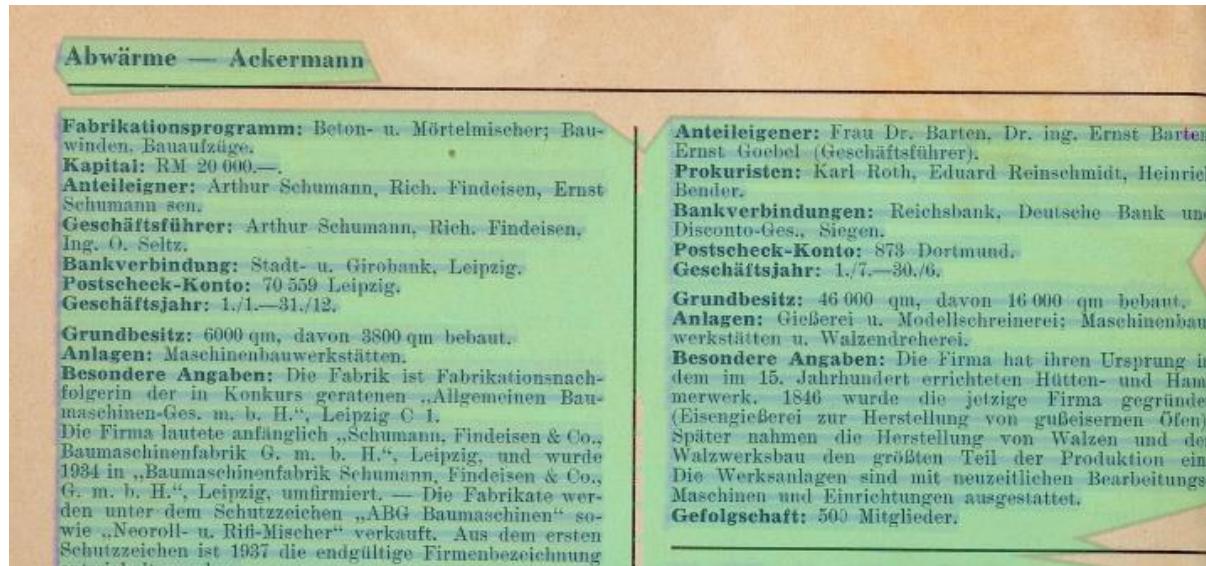
<https://pypi.org/project/blatt>

<https://github.com/UB-Mannheim/blatt>

3. Extraction and Structuring via Python: Segmentation

OCR segmentation of the text regions with problems

blatt



1. sorts text lines
2. makes geometric segmentation based on coordinates
3. data cleaning
4. merges segments of subsequent columns and pages

3. Extraction and Structuring via Python: Segmentation

JPG



Transformation
via blatt

Approach: use colon as separator

Problem: inconsistent attribute naming, printing mistakes, OCR errors

e.g.: OCR problems:

{'Postscheck-Konto ', 'Postseheck-Konto','PostscheckKonto', 'Postscheck-Konnto', 'Fostscheck-Konto', Postcheck-Konto', 'Postscheek-Konto', 'Potscheck-Konto','Postscbeck-Konto', 'Postscheckkonto', 'Postschek-Konto','Postscheck-Konten', 'Ponstscheck-Konto', 'Postscheck-Konto'}

Structured
research data

Firma	Piccolo-Automaten G.m.b.H., Berlin W 35, Kurfürstenstraße 146
Rechtsform	G.m.b.H.
Fernruf	212095
Drahtanschrift	piccoloautomat
Gründung	1932
Produkt	Schokoloaden-Verkaufsapparate (Tischautomaten, Kugelstechapparate)
	...

Sorting and grouping of properties

Postscheck-Konto

```
{'Postscheck-Konto', 'Postseheck-Konto','PostscheckKonto', 'Postscheck-Konnto', 'Fostscheck-Konto', Postcheck-Konto',  
'Postscheek-Konto', 'Potscheck-Konto','Postscbeck-Konto', 'Postscheckkonto', 'Postschek-Konto', 'Postscheck-Konten',  
'Ponstscheck-Konto', 'Postscheck-Konto'}
```

Geschäftsjahr

```
{'Geschäftsjahr', 'Geschäftsjaehr', 'Gescbäftsjaehr', 'Geschäftsjaehr', '.Geschäftsjaehr'}
```

Fabrikationsprogramm

```
{'Fabfikationsprogramm', 'Fabrikationprogramm','Fabrikationsproramm', 'Fabrikationsprogramm:',  
'Fabrikstionsprogramm', 'Fabrkkationsprogramm','Fabrikationsprogramm'}
```

3. Extraction and Structuring via Python: Post-Processing

Extract *Drahtanschrift* from *Fernruf*:

Fernruf: 212095. *Drahtanschrift*: piccoloautomat



Fernruf	212095
Drahtanschrift	piccoloautomat

Extraction of the legal form:

{'m. b. H.', 'G. m. b. H.', 'Gesellschaft m. b. H.',
'G.m.b. H.', 'Ges. m.b. H.', 'GmbH', 'G. m. b.H.',
'mit beschr. Haftung', 'Ges.m.b.H.', 'G.m.b.H.',
'GmbH.', 'GmbH'}

{'A.-G.', 'Aktien-Gesellschaft', 'Actien-Gesellschaft',
'Aktiengesellschaft', 'Akt.-Ges.', 'Aktien-Gesellsch.',
'A. G.'}

{'K.-G.', 'Kom.-Ges.', 'Komm.-Ges.', 'KG.',
'Kommanditgesellschaft', 'Kom. Ges.', 'Komm.-
Ges.'}

3. Extraction and Structuring via Python: CSV and XLSX

Structured research data

Firma	Piccolo-Automaten G.m.b.H., Berlin W 35, Kurfürstenstraße 146
Rechtsform	G.m.b.H.
Fernruf	212095
Drahtanschrift	piccoloautomat
Gründung	1932
Produkt	Schokoloaden- Verkaufsapparate (Tischautomaten, Kugelstechapparate)

...

CSV and XLSX

	Company	RAW_TEXT	N_TEXT	LE_SEGMENT	FABRIKATIONSPROGRAMM	POSTSCHECK-KONTO	FERNRUF	DRAHTANSCHRIFT	BANKVERBINDUNGEN	ANLAGEN
0	Aachener Kratz	Aachener K Cassalette & Aachen, Oli Fernruf: 34 Gründung: Fabrikation Verwendun Kapital: RM Geschäftsfü Prokuristen Bankverbin Disconto-G Postscheck								
1	Aachener Masch	Aachener N Aachen, Ru Fernruf: 25 Drahtansch Gründung: Fabrikation zur Herstell Drahtartike die Kratzen Bankverbin bank A.-G.,								
2	Aachener N Rothe & Ste	Aachener N Aachen, Bis Fernruf: 25 Gründung: Fabrikation Lieferung v samte Kratzi Kapital: RM Anteileigne Peter Rumpf								

4. Summary

Alle Inhalte dieser Präsentation stehen unter der [Lizenz Creative Commons BY 4.0 International](#), sofern nicht anders angegeben.



4. Summary

Results:

- Very good text recognition accuracy (> 99.85%) through work-specific training
- eScriptorium very well suited as a platform for ground truth production and training:
 - fast, user-friendly, platform-independent production of transcriptions
 - user-friendly training process (GUI)
- Data structuring:
 - no all-in-one solution → we developed the open source tool *blatt* → it can be reused in similar projects
 - we structured all available data (not only legal forms) → the data can be reused to answer other research questions
- The services of UB Mannheim can be used flexibly and cooperatively in projects with other stakeholders of the University

Phönix — Pincuss

Phönix-Werk G. m. b. H., Spezialfabrik moderner Trocken- Apparate, Meerane (Sa.).

Fernruf: 3284. Drahtanschrift: phönixwerk
Gründung: 1907.
Fabrikationsprogramm: Trockenapparate; Holzbearbeitungs-Maschinen.
Kapital: RM 17 500.—.
Anteilseigner: C. R. Nestmann, Meerane (100%).
Geschäftsführer: Obering, A. Wackermann.
Prokurist: J. Frenzel.
Bankverbindungen: Meeraner Bank A.-G., Reichsbank, Meerane.
Postcheck-Konto: 115 485 Leipzig.
Geschäftsjahr: 1./1.—31./12.

Grundbesitz: 3700 qm, davon 1462 qm bebaut.
Anlagen: Fabrikationsräume mit Montagehalle, elektr. Schleiferei, Zellerei, u. ähnlichem; an anderer allgemeiner Trocknungsanlage 1921 erfolgte nach dem Erwerb der Anlage die Aufnahme der Fabrikation von Holzbearbeitungsmaschinen. 1932 übernahm das Werk zusätzlich die Herstellung von Bewoid-Apparaturen für die Papierindustrie nach den Patenten Dr. Bruno Wiegner, Berlin.

Piccolo-Automaten G. m. b. H., Berlin W 35, Kurfürstenstraße 146.

Fernruf: 21 20 05. Drahtanschrift: piccoloautomat
Gründung: 1932.
Fabrikationsprogramm: Schokoladen-Vorverkaufsaparate (Tischautomaten, Kugelstechapparate).

Kapital: RM 20 000.—.
Anteilseigner: Dr. Richard Schönthal, Wien.
Geschäftsführer: Erwin Hantsch, Bln.-Steglitz.
Bankverbindung: Deutsche Bank u. Disconto-Ges., Berlin.
Postcheck-Konto: 8012 Berlin.
Geschäftsjahr: 1./1.—31./12.
Anlagen: Mechanische Werkstätten.
Gefolgschaft: 13 Arbeiter u. 6 Angestellte.

F. Piechatzek, Kran- u. Aufzug-Werke, Berlin N 65, Seestraße 51-56.

Fernruf: 46 43 11. Drahtanschrift: Höderzug
Gründung: 1923.
Fabrikationsprogramm: Krane u. Aufzüge, Hebezeuge u. Hobemaschinen (Flaschenzüge, Laufkatzen, Winden, Elektro-Flaschenzüge).

Geschäftsführer: Richard, Martin u. Paul Piechatzek.
Prokuristen: Paul Gräning, Alfred Knop, Otto Kuhwald.
Bankverbindung: Reichskredit-Gesellschaft A.-G., Berlin.
Postcheck-Konto: 4847 Berlin.
Geschäftsjahr: Kalenderjahr.

Grundbesitz: 9500 qm, davon 4500 qm bebaut.
Anlagen: Maschinenbau-Werkstätten (Dreherei, Schleiferei, Fräserei, Presserei u. Schlosserei).
Eigene Vertretungen: Im Ausland.
Besondere Angaben: Der Export erstreckt sich auf alle Weltteile.
Gefolgschaft: 350 Mitglieder.

Otto Pieron
siehe Maschinenfabrik

Paul Pietzschmann Wasserwerksbau, Berlin-Spandau, Schönwalder Str. 34.

Fernruf: 37 68 71.
Gründung: 1932.
Fabrikationsprogramm: Entwurf und Bau von Trink- und Gebrauchswasserwerken jeder Größe. Entsiedlungsanlagen einschl. der erforderlichen Antriebsanlagen (Dampf — Diesel — Wasserkraft, Hoch- und Niederspannung).
Inhaber: Ing. Paul Pietzschmann.
Bankverbindungen: Dresdner Bank, Spandauer Bank, Spandau.

Besondere Angaben: Der Firmeninhaber beschäftigt sich hauptsächlich mit der Erstellung halb- u. vollautomatisch arbeitender Wasserwerke u. besitzt hierüber große u. langjährige Erfahrungen.

Anton Piller Maschinenfabrik, Osterode (Harz), Abgunt 24.

Fernruf: 211. Drahtanschrift: apo
Gründung: 1900.
Fabrikationsprogramm: Ventilatoren für Heizungs-, Lüftungs-, Absaug- u. sonstige Zwecke.
Bankverbindung: Reichsbank, Städt. Sparkasse, Osterode a. H.
Postcheck-Konto: 40 278 Hannover. ×

Pilot. G. m. b. H.
siehe Maschinenfabrik

Friedrich Piltz & Sohn K.-G., Heidenheim a. d. Brenz, Friedrichstr. 9.

Fernruf: 637. Drahtanschrift: piltz
Gründung: 1963.
Fabrikationsprogramm: Genauigkeitswerkzeuge für Herstellung u. Kontrolle von Gewinden; Gewindeschleifmaschinen, Schleifzangen, Schleifpulte.
Gesellschafter: Otto u. Walther Piltz.
Geschäftsführer: Die Gesellschafter.
Bankverbindungen: Reichsbank, Deutsche Bank u. Disconto-Ges., Heidenheim.
Postcheck-Konto: 2178 Stuttgart.
Geschäftsjahr: Kalenderjahr.

Grundbesitz: 2600 qm, davon 2000 qm bebaut; gepachtet sind 1200 qm mit 700 qm bebauter Fläche.
Anlagen: Ventilatoren- u. Fabrikationsräume in Heidenheim u. München.

Besondere Angaben: In München befindet sich ein Zweigwerk der Gesellschaft.

Eduard Pincuss Armaturenfabrik, Sanitäre Einrichtungen, Berlin O 17, Gr. Frankfurter Str. 13.

Fernruf: 59 13 18. Drahtanschrift: epal
Gründung: 1859.
Fabrikationsprogramm: Wasserleitungs-Armaturen.
Inhaber: Arthur Landsberger, Bln.-Charlottenburg; Ernst Reichenbach, Bln.-Grunewald.
Prokuristen: Paul Dorpsch, Frieda Thierschmann.

Time investment:

- **Total:** approx. 2 work weeks (spread over 2 months)
- **Digitization:** 1 work day
- **OCR:** 1 work week:
 - Evaluation of existing OCR models on the material
 - Design of an OCR workflow (layout segmentation + OCR)
 - Ground truth production and subsequent training (layout segmentation + OCR)
 - Final OCR for all pages
- **Data structuring:** 1 work week:
 - Segmentation
 - Post-processing
 - Extension of *blatt*

Team:

- **6 Project participants**
 - Prof. Jochen Streb (**Chair of Economic History**)
 - 1 research assistant for ground truth production and QA (**Chair of Economic History**)
 - 1 project manager for digitization (**UB Mannheim**)
 - 1 project coordinator + OCR (**UB Mannheim**)
 - 1 developer OCR (**UB Mannheim**)
 - 1 developer data structuring (**BERD@NFDI, UB Mannheim**)

Feedback, Questions?

Jan Kamlah (Development): jan.kamlah@uni-mannheim.de

Renat Shigapov (Development): renat.shigapov@uni-mannheim.de

Thomas Schmidt (Project coordination): thomas.schmidt@uni-mannheim.de

Thank You!

<https://github.com/UB-Mannheim/Maschinen-Industrie>

Funded by the Deutsche Forschungsgemeinschaft (DFG, German Research Foundation) – 460037581