



Fachhochschul-Bachelorstudiengang

SOFTWARE ENGINEERING

A-4232 Hagenberg, Austria

Kategorisierung von lokalisierten Bilddateien mittels OCR

Bachelorarbeit

zur Erlangung des akademischen Grades
Bachelor of Science in Engineering

Eingereicht von

Simon Gruber

Begutachtet von Barbara Traxler MSc

Hagenberg, Oktober 2023

Erklärung

Ich erkläre eidesstattlich, dass ich die vorliegende Arbeit selbstständig und ohne fremde Hilfe verfasst, andere als die angegebenen Quellen nicht benutzt und die den benutzten Quellen entnommenen Stellen als solche gekennzeichnet habe. Die Arbeit wurde bisher in gleicher oder ähnlicher Form keiner anderen Prüfungsbehörde vorgelegt.

Die vorliegende, gedruckte Bachelorarbeit ist identisch zu dem elektronisch übermittelten Textdokument.

Datum

Unterschrift

Inhaltsverzeichnis

Kurzfassung	v
Abstract	vi
1 Einleitung	1
1.1 Motivation	1
1.2 Ziele	2
1.3 Fragestellung	2
2 Grundlagen	3
2.1 Stand der Technik	3
2.1.1 Texterkennungssysteme	3
2.1.2 Filterung der Ergebnisdaten	3
2.2 Verwendete Technologien	4
2.2.1 Texterkennungssystem	4
2.2.2 Bildbearbeitungswerkzeug	4
3 Konzept	5
3.1 Annahmen	5
3.1.1 Vorverarbeitung	5
3.1.2 Nachbearbeitung	6
3.2 Vergleich	7
3.2.1 Metriken	7
3.2.2 Testaufbau	10
3.3 Verwendete Algorithmen	10
3.3.1 Vorverarbeitung	10
3.3.2 Nachbearbeitung	17
4 Implementierung	22
4.1 Implementierung	22
4.1.1 Vergleichsdaten	22
4.1.2 Verwendete Bibliotheken	23
4.1.3 Programmablauf	28
4.2 Evaluierung	29
4.2.1 Vergleich im Detail	30

Inhaltsverzeichnis	iv
4.2.2 Prozessoren im Überblick	32
5 Zusammenfassung	35
Quellenverzeichnis	39
Literatur	39
Medien	41

Kurzfassung

Optische Texterkennung ist in der heutigen Zeit von immer größerer Bedeutung und wird in vielen Industrien dafür genutzt, effizient textuelle Informationen aus Fotos und digitalen Bildern zu gewinnen. Diese Bachelorarbeit widmet sich einem der Anwendungsgebiete von optischer Texterkennung, der Erkennung von Textdaten in Oberflächenscreenshots, und versucht, die Menge und Qualität der gewonnenen Daten zu maximieren. Dazu werden verschiedene Vorgehensweisen zur Aufbereitung der Bilder, sowie der Nachbearbeitung der erkannten Textdaten exemplarisch miteinander verglichen und anhand festgelegter Qualitätskriterien analysiert.

Die zentrale Fragestellung der Arbeit zielt darauf ab, die beste Methodik für die Texterkennung zu identifizieren und die Resultate zu optimieren. Somit wird die Verwaltung der Produktdokumentation von COPA-DATA vereinfacht und gleichzeitig ein Beitrag zur Forschung im Bereich der Texterkennung in grafischen Oberflächen geleistet.

Um die Forschungsfrage zu beantworten, wird eine Auswahl von Algorithmen für die Bild- und Textbearbeitung getroffen. Diese Algorithmen werden in ihrer Grundfunktion erklärt und die Ergebnisse der Texterkennung anhand einer Stichprobe untersucht. Durch die Anwendung gängiger Metriken für die Sprach- und Texterkennung werden die jeweiligen Algorithmen objektiv miteinander verglichen und in einen automatisch generierten Bericht eingetragen. Dieser beinhaltet eine detaillierte Übersicht aller Ergebnisse der Texterkennung und bildet die Grundlage für die Auswertung.

Die Analyse aller Ergebnisdaten im Bericht erteilt Aufschluss darüber, welche Algorithmen in welchen Szenarien die besten Ergebnisse liefern. Die größte Auswirkung auf die Ergebnisdaten hat der Austausch des Thresholding- bzw. Binarisierungsverfahrens: Werden unpassende Parameter oder Verfahren genutzt, wird nur ein Bruchteil des verfügbaren Texts erkannt. Wird das passende Verfahren gewählt, wird ein Großteil der Daten korrekt vom Texterkennungssystem erkannt.

Für weitere Forschung oder Anpassung an spezifische Anforderungen kann die prototypische Implementierung bzw. die jeweiligen Komponenten wiederverwendet werden. Durch den modularen Aufbau des automatischen Vergleichssystems kann selbst nach Änderung der Anzeigesprache oder einer farblichen Neugestaltung der grafischen Oberfläche stets mit wenig Aufwand die ideale Vorgehensweise zur Texterkennung ermittelt werden.

Abstract

Kapitel 1

Einleitung

1.1 Motivation

Die in Salzburg ansässige COPA-DATA GmbH bietet die Softwareplattform zenon an, die als umfassende Gesamtlösung Unternehmen in zahlreichen Anwendungsgebieten bei der Automatisierung ihrer Herstellungsprozesse unterstützt [26].

Die zenon-Plattform kann sowohl vom Kunden selbst, als auch durch das Professional Services Team individuell auf Kundenanforderungen zugeschnitten und in bestehende Prozesse eingebunden werden. Den Grundstein für die hohe Anpassungsfähigkeit bildet die Produktdokumentation, in der Schnittstellendokumentation, Anleitungen und Beispiele in verschiedensten Sprachen, Formaten und mit kundenspezifischen Erweiterungen umfassend sowohl für Mitarbeiter, als auch für Kunden festgehalten sind.

In der Produktdokumentation werden, besonders in Hinblick auf die grafischen Tools wie die zenon Engineering Studio Entwicklungsumgebung oder die zenon Service Engine, zahlreiche Grafiken verwendet, um Beispiele verständlicher zu machen und Anleitungen übersichtlicher zu gestalten. Um bei dem großen Funktionsumfang der zenon-Tools, den vielen Sprachen, Anpassungen und den unterschiedlichen Themengebieten innerhalb der Dokumentation nicht den Überblick zu verlieren, benötigt das interne „Technical Content and Translation“ Team unterstützend zu dem intern verwendeten CMS eine dedizierte Anwendung zur Verwaltung von sprachabhängigen Bilddateien.

Während das Programm auch die Basisfunktionalität, das Speichern, Bearbeiten, Löschen, Abrufen beziehungsweise das generelle Verwalten von Screenshots und der zugehörigen Metainformation abdecken soll, konzentriert sich diese Bachelorarbeit primär auf die Kategorisierungsfunktionalität der Bildinhalte.

Mithilfe von optischer Texterkennung (engl. *Optical character recognition*, kurz: *OCR*) soll es den Mitarbeitern möglich gemacht werden, hochgeladene Screenshots und Grafiken aufgrund ihrer Inhalte zu verschlagworten, um sie später anhand dieser suchen zu können.

1.2 Ziele

Das Ziel dieser Bachelorarbeit ist das Ermitteln einer Vorgehensweise für Texterkennung in Screenshots von grafischen Oberflächen. Verschiedene Algorithmen zur Bildbearbeitung vor der Texterkennung oder Nachbearbeitung bzw. Filterung der Ergebnisdaten werden evaluiert und anhand von festgelegten Qualitätskriterien analysiert.

Die prototypische Implementierung dient als Basis für jegliche Tests und Analysen, anhand derer die Algorithmen automatisch verglichen werden. Die entwickelten Komponenten werden als Bibliotheken zur Verfügung gestellt, um die Texterkennung inklusive automatischer Bildverarbeitung und Filterung der erkannten Inhalte bzw. Schlagworte später in anderen Anwendungen weiterverwenden zu können.

1.3 Fragestellung

Ziel dieser Bachelorarbeit ist es, herauszufinden, welche Vorgehensweisen bei der Texterkennung zu den besten Ergebnissen führen. Dazu werden die Resultate der Bild- und Textverarbeitung anhand gängiger Fehlermetriken für Texterkennungssysteme verglichen.

Kapitel 2

Grundlagen

2.1 Stand der Technik

2.1.1 Texterkennungssysteme

Optische Texterkennung wird in der Informationstechnik eingesetzt, um Textinhalte aus gedruckten oder digital rasterisierten Medien zu extrahieren. Dieses Verfahren kann für diverse Anwendungsgebiete genutzt werden, wie beispielsweise für Handschrifterkennung oder für das Ablesen von Nummernschildern eines Autos [1]. Auf dem Markt gibt es dafür bereits viele kommerzielle Komplettlösungen wie „IronOCR“ [30], „Google Cloud Vision“ [27], „Amazon Textract“ [22] oder „Microsoft Azure Computer Vision“ [24], die oftmals gute Ergebnisse mit geringen Fehlerraten erzielen und sich in bestehende Prozesse oder Anwendungen integrieren lassen [5, 18].

Heutige Texterkennungssysteme arbeiten oft mit einer Kombination aus neuronalen Netzwerken und fortgeschrittenen Bildverarbeitungsalgorithmen, um Texte zu erkennen. Während es zahlreiche wissenschaftliche Werke zur grundlegenden Funktionsweise von optischen Texterkennungswerkzeugen gibt (beispielsweise [4] oder [6]), werden die genauen Schritte zur richtigen Vorbereitung der Bilddaten – besonders in Bezug auf Screenshots – oftmals nur oberflächlich behandelt.

2.1.2 Filterung der Ergebnisdaten

Das Themengebiet des Natural Language Processing beschäftigt sich mit der Interaktion zwischen menschlicher Sprache und Computern. Techniken aus der Informatik, Linguistik und dem maschinellen Lernen werden kombiniert, um mit menschlicher Sprache umzugehen und beispielsweise Textanalyse, Übersetzungen, Spracherkennung oder Dialogsysteme möglich zu machen [2]. Durch die große Aufmerksamkeit und die vielseitige Nutzung der Technologien – von automatischer Rechtschreibkontrolle bis hin zu digitalen Sprachassistenten – sowie dem Aufkommen von neuronalen Netzwerken wurden in diesem Forschungsgebiet in den letzten Jahren immer wieder Fortschritte erzielt [3, 7].

Dadurch gibt es zahlreiche wissenschaftliche Ressourcen, die als Grundlage für die Vorgehensweise zur Interpretation und Extraktion relevanter Schlagworte aus den erkannten Freitextdaten dienen.

2.2 Verwendete Technologien

2.2.1 Texterkennungssystem

Die Nutzung der in Kapitel 1 erwähnten Anwendungen bzw. Dienstleistungen ist kostenpflichtig und die genaue innere Vorgehensweise dieser Programme ist nicht öffentlich bekannt [23, 25, 28]. Aufgrund dieser Tatsachen ist die Wahl des Texterkennungssystems für die prototypische Implementierung dieser Bachelorarbeit auf die seit 2005 unter der Freie-Software-Lizenz „Apache 2.0“ veröffentlichten „Tesseract Open Source OCR Engine“ (kurz: Tesseract) gefallen [14]. Diese basiert seit der Major-Version 4 auf einem neuronalen Netz, durch welches mithilfe von sprachspezifischen Trainingsdaten Texte in Bildern erkannt werden können [31].

2.2.2 Bildbearbeitungswerkzeug

Als Werkzeug für die Durchführung der notwendigen Bildbearbeitungsschritte wurde die Softwarebibliothek „ImageMagick“ [29] gewählt. Sie ist umfassend dokumentiert, flexibel und kann Dank der Unterstützung für eine Vielzahl von Programmiersprachen direkt in Programme eingebunden werden. Viele in der Bildverarbeitung genutzte Operationen sind bereits implementiert, was schnelles Prototyping vereinfacht und die Bibliothek zu einer idealen Wahl für die Realisierung von Bildbearbeitungsschritten in der prototypischen Implementierung macht.

Kapitel 3

Konzept

3.1 Annahmen

Um die Texterkennung mittels Tesseract und die anschließende Filterung der Ergebnisdaten zu verbessern, werden anwendungsspezifische Annahmen für den Verarbeitungsablauf festgelegt.

3.1.1 Vorverarbeitung

3.1.1.1 Eigenschaften von Screenshots

Die zu verarbeitenden Bilder im Kontext dieser Bachelorarbeit sind ausschließlich digitale Bildschirmaufnahmen von grafischen Benutzeroberflächen. Es kann also angenommen werden, dass die Screenshots keine Transparenz aufweisen, die Perspektive der Aufnahme nicht verzerrt ist. Im Großteil der evaluierten Fälle ist auch der Kontrast ausreichend, um die relevanten Inhalte zu erkennen. Weiters ist bei der Bildverarbeitung auf farbige Hintergrundflächen zu achten, mit deren Unterstützung Bildelemente in modernen grafischen Oberflächen oft markiert, gruppiert oder getrennt werden. Nach Sichtung des zu verarbeitenden Bilddatensatzes fällt auf, dass manche Screenshots durch das Selektieren mit der Maus sehr eng abgeschnitten wurden. Das ist bei dem Preprocessing ebenfalls zu berücksichtigen. Eine beispielhafte Auswahl typischer Screenshots findet sich in Abbildung 3.1.

3.1.1.2 Optimieren von Daten für Tesseract

Für die Verwendung von Tesseract ist es wichtig, unabhängig von der Diversität der Ausgangsdaten möglichst einheitliche Bilder zu erzeugen [31]. Während störende Elemente wie Bildrauschen aus dem Bild entfernt werden, sollen Texte ohne Einfluss der eigentlichen Hinter- bzw. Vordergrundfarbe gut zu erkennen sein. Auch eine deutliche Abgrenzung von Formen oder grafischen Symbolen ist von großer Wichtigkeit [16] [11]. Wurde ein Screenshot ideal vorbereitet, wie in Abbildung 3.2 gezeigt, verschwinden farbige Hintergrundflächen und grafische Dekorationselemente. Übrig bleibt nur der gut lesbare textuelle Inhalt des Bildes.




Abbildung 3.1: Beispielhafte Auswahl typischer Dialogscreenshots.




Abbildung 3.2: Ein optimales Ergebnisbild. Jegliche farblichen Flächen wurden durch die Bildverarbeitung entfernt. Übrig bleibt klar lesbarer Text mit einem hohen Kontrast zum Hintergrund.

3.1.2 Nachbearbeitung

3.1.2.1 Filtern von Symbolen

Bei der Texterkennung kann es vorkommen, dass grafische Elemente als diverse Unicode-Symbole erkannt werden. Wie in Abbildung 3.3, wird oftmals versucht, grafische Dekorationselemente textuell nachzubilden. Auch finden sich in den ungefilterten Ergebnisdaten oft Aufzählungszeichen wie „•“ oder unterschiedliche Varianten von Bindestrichen „–“. Diese Zeichen sind gemäß Anwendungsanforderungen nicht relevant für die Schlagwortsuche und können somit entfernt bzw. ignoriert werden.

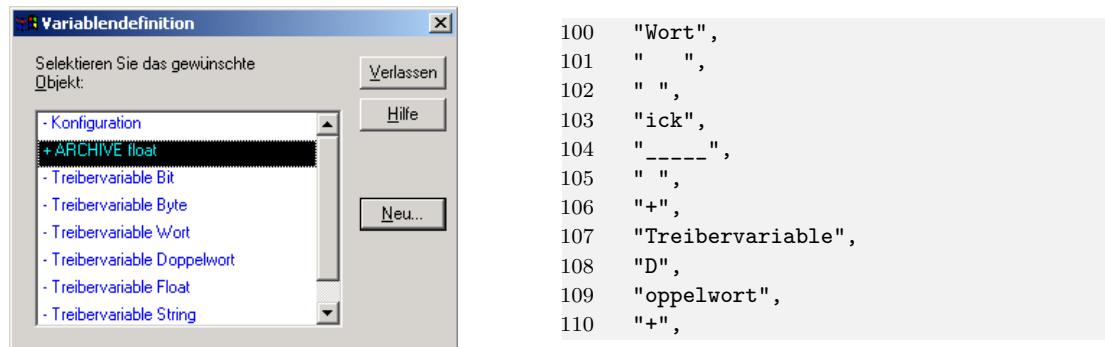


Abbildung 3.3: Auszug aus den ungefilterten Ergebnisdaten bei Durchführung der Texterkennung in dem gezeigten Screenshot.

3.1.2.2 Mehrsprachigkeit

Das Textverarbeitungssystem muss in der Lage sein, mehrsprachige Bilddateien einlesen und interpretieren zu können. So sollen beispielsweise Bilder mit englischen, deutschen oder italienischen Inhalten zugeführt und die Ergebnisdaten richtig verarbeitet werden können. Um eine Filterung für verschiedene Zeichensätze zu ermöglichen und eine Unterstützung für Sprachen mit nicht-lateinischen Schriften zu gewährleisten, werden dynamische Sprachfilter verwendet, die individuell an die jeweilige Sprache angepasst werden können. Für die weitere Beschreibung der generellen Vorgehensweise und Tests werden in den folgenden Schritten jedoch nur deutsche oder englische Inhalte verwendet.

3.1.2.3 Schlagworte

Für die spätere Suche von Screenshots sollen relevante Schlagworte aus den erkannten Textdaten extrahiert werden. Ein Wort eignet sich dann als Schlagwort, wenn es in relevantem Bezug zum jeweiligen Bild steht und dabei eine wichtige Aktion oder Information widerspiegelt. Inhalte, die direkt in der grafischen Benutzeroberfläche ersichtlich sind, haben daher einen hohen Informationsgehalt und eignen sich besonders gut als Suchwörter. Um die Schlagwortmenge so aussagekräftig wie möglich zu halten, müssen Wörter mit geringer Bedeutung entfernt werden. Beispielsweise haben sogenannte Stoppwörter (engl. *Stop words*) wie *und* oder *oder* keine besondere Semantik und fördern aufgrund ihrer Häufigkeit das Auftreten von Verwechslungen [20].

3.2 Vergleich

3.2.1 Metriken

Um die erkannten Ergebnisse unter Verwendung der verschiedenen Pre- und Postprocessing Schritte mittels eines einheitlichen Systems vergleichen zu können, wird auf die in der optischen Texterkennung gängigen Metriken „Character Metric“, auch bekannt als „Character Error Rate“ und „Word metric“ bzw. „Word Error Rate“ [9], basierend

auf der Levenshtein-Distanz [10] zurückgegriffen.

Sowohl die Character- als auch die Word Error Rate sind häufig genutzte Vergleichswerte, die ihren Ursprung in der computergestützten Sprachverarbeitung bzw. automatischen Spracherkennung haben [19]. Da die optische Texterkennung und die automatische Spracherkennung jeweils darauf abzielen, maschinenlesbaren Text aus nicht-strukturierten Daten zu extrahieren, sind die Prinzipien dieser Metriken auch auf die optische Texterkennung anwendbar [17].

3.2.1.1 Word Error Rate

Die Wortfehlerrate (engl. *Word Error Rate*, kurz: *WER*) beschreibt den prozentualen Anteil der falsch erkannten oder fehlenden Wörter eines Textes im Vergleich zu einer Referenz, welche im Falle der folgenden Vergleiche immer alle sichtbaren Texte im Bild repräsentiert. Je niedriger die WER, desto genauer ist der OCR-Vorgang. Um die WER zu berechnen, bildet man die Summe aller notwendigen Ersetzungen, Entfernungen und Einfügungen, um aus dem erkannten Text den Referenztext bilden zu können und setzt sie mit der Gesamtwortanzahl im Referenztext in Verhältnis [9, 10, 13].

Berechnung

Die mathematische Formel für die Word Error Rate lautet somit wie folgt [9]:

$$\text{WER} = \frac{S + D + I}{N}$$

wobei die einzelnen Komponenten folgende Größen darstellen:

- S beschreibt die Anzahl der falsch erkannten Wörter (engl. *Substitutions*)
- D beschreibt die Anzahl der im Resultat fehlenden Wörter (engl. *Deletions*)
- I beschreibt die Anzahl der im Resultat fälschlicherweise eingefügte Wörter (engl. *Insertions*)
- N beschreibt die Gesamtanzahl der Wörter in der Referenz

Vorteile und Nachteile

Die WER spiegelt ohne großen Rechenaufwand direkt wider, wie stark die erkannten Texte der Referenz gleichen. Hierbei werden fehlerhafte Einsetzungen, Löschungen und falsch erkannte Wörter bzw. Teilwörter gleichermaßen gewichtet. Es ist jedoch nicht möglich, die korrekte Reihenfolge der erkannten Wörter darzustellen oder bestimmte wichtige Stellen im Text höher zu gewichten als andere. Zudem werden fehlerhaft erkannte Wörter als vollwertige Ersetzung wahrgenommen, auch wenn nur ein einzelnes Zeichen falsch ist. Dadurch wird das Ergebnis stark beeinflusst.

Um die Verfälschung der Ergebniswerte durch die WER möglichst gering zu halten, muss mindestens eine weitere Fehlermetrik, beispielsweise die Character Error Rate, zum Vergleich verwendet werden.

3.2.1.2 Character Error Rate

Die Zeichenfehlerrate (engl. *Character Error Rate*, kurz: *CER*) beschreibt die Anzahl der falsch erkannten oder fehlenden Zeichen im Vergleich zu einem Referenzwort und basiert wie die Word Error Rate auf der Levenshtein-Distanz [10]. Je niedriger die CER, desto genauer ist der OCR-Vorgang. Ähnlich wie die WER wird die CER aus der Summe aller Ersetzungen, Entfernungen und Einfügungen, notwendig um aus dem erkannten Wort die Referenz bilden zu können, gebildet [10]. Diese Summe wird anschließend durch die Zeichenanzahl des Referenzwortes geteilt [9, 13].

Berechnung

Das Verfahren zur Ermittlung der CER gleicht im Wesentlichen dem der WER. Die mathematische Formel lautet somit wie folgt [9]:

$$\text{CER} = \frac{S + D + I}{N}$$

wobei die einzelnen Komponenten folgende Größen darstellen:

- S beschreibt die Anzahl der falsch erkannten Zeichen (Substitutions)
- D beschreibt die Anzahl der im Resultat fehlenden Zeichen (Deletions)
- I beschreibt die Anzahl der im Resultat fälschlicherweise eingefügte Zeichen (Insertions)
- N beschreibt die Gesamtanzahl der Zeichen in der Referenz

Vorteile und Nachteile

Die CER fasst in einem Wert zusammen, wie viele Änderungen auf Zeichenebene notwendig sind, um aus dem erkannten Wort das Referenzwort zu bilden. Es ist dabei wie bei der WER nicht relevant, in welcher Reihenfolge diese Zeichen auftreten. Ebenso gibt es keine gesonderte Gewichtung für Ersetzungen, Löschungen oder Einfügungen, wodurch besonders bei kurzen Wörtern auch kleinere Abweichungen bereits zu einer hohen CER führen können.

Durch den detaillierten Vergleich der einzelnen Wörter auf Zeichenebene stellt die CER jedenfalls ein ausreichend gutes Komplement zur WER dar, um in den folgenden Vergleichen genutzt werden zu können.

3.2.2 Testaufbau

Der Testaufbau im Rahmen der Implementierung, beschrieben in Abschnitt 4.1, erlaubt ein dynamisches Verketteten von unterschiedlichen Bildverarbeitungs- und Textfilterungsschritten. Für einen objektiven Vergleich zwischen den verschiedenen Vorgehensweisen und Algorithmen wird eine Grundabfolge der jeweiligen Schritte in einer „Processing-Pipeline“ definiert. Die Ergebnisse können schließlich anhand der in Unterabschnitt 3.2.1 beschriebenen Fehlermetriken mit einer durch den Menschen verschlagworteten Vergleichsmenge abgeglichen werden.

3.3 Verwendete Algorithmen

3.3.1 Vorverarbeitung

Beim sogenannten „Preprocessing“ werden die zu verarbeitenden Bilder für die Texterkennung vorbereitet, um die Qualität der erkannten Textdaten zu verbessern.

Verwendet man moderne Tesseract-Implementierungen, sind in diesen oft bereits rudimentäre Bildverarbeitungswerkzeuge verfügbar [31]. Mit diesen Werkzeugen werden die eingespeisten Bilder – sofern nicht bereits im richtigen Format – automatisch für die Texterkennung vorbereitet. Ohne weitere Einstellungen zu treffen, bewirkt diese Bildverarbeitung ein Umwandeln der Eingangsgrafiken in ein meist gut für Tesseract geeignetes Bild. Es ist jedoch zu beachten, dass die Bildverarbeitungsschritte individuell auf die erwarteten Eingangsdaten anzupassen sind. So können die Bilddaten den in Unterabschnitt 3.1.1.2 definierten optimalen Tesseract-Eingangsdaten angenähert werden.

Die folgenden Preprocessing-Schritte basieren auf der empfohlenen Vorgehensweise zur Verbesserung der Output-Qualität laut Tesseract-Dokumentation [31]. Gemäß den obigen Annahmen werden jedoch weder perspektivische Fehler, noch ein eventuelles Rauschen korrigiert. Konkret werden folgende Bildverarbeitungsschritte verglichen:

3.3.1.1 Resampling

Bei Resampling wird die Bildauflösung durch Interpolation verändert. Interpolation beschreibt die Methode, fehlende Pixelwerte zwischen bekannten Punkten mittels eines festgelegten Verfahrens zu ergänzen. Abhängig vom gewählten Verfahren ist das Ergebnis meist ein glattes und kontinuierliches Bild. Um die für Tesseract optimale Mindestauflösung von 300 dpi [31] zu gewährleisten, muss das Eingangsbild, sofern es die Mindestauflösung unterschreitet, zunächst entsprechend vergrößert werden.

Da Tesseract auf klare und scharfe Kontraste angewiesen ist, um Text korrekt zu identifizieren, eignen sich nicht alle von ImageMagick zur Verfügung gestellten Skalierungsmethoden für die Weiterverarbeitung. Wie in Abbildung 3.4 zu sehen ist, neigen einige Filter besonders beim Hochskalieren dazu, Unschärfen oder Artefakte zu erzeugen, die die Genauigkeit der Texterkennung negativ beeinflussen können.

Nach einigen Tests fällt auf, dass Bilder, die mittels des Spline-Verfahrens oder der Hermite-Interpolation skaliert wurden, weiche Konturen ohne harte Farbübergänge auf-

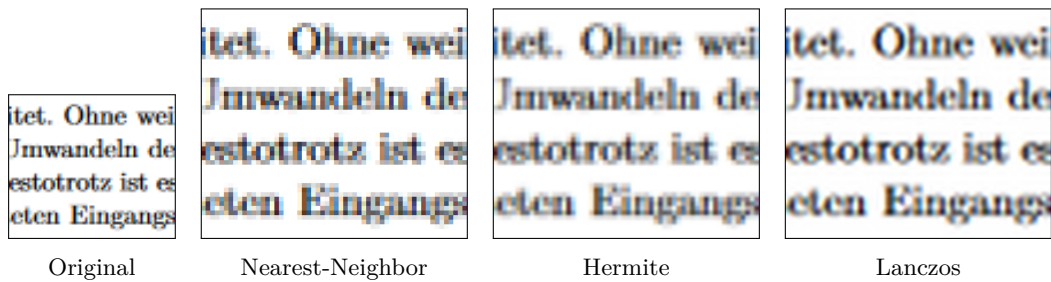


Abbildung 3.4: Ein Vergleich unterschiedlicher Resampling-Filter. Durch die Aufteilung der Fehler auf mehrere Pixel bleiben Details und Konturen bei Anwendung des Lanczos-Filters vergleichsweise gut erhalten und der Text ist gut lesbar.

weisen. Tesseract profitiert jedoch stark von klaren Texten und hohen Kontrasten, weswegen diese Art des Resamplings keine ideale Basis für das Preprocessing bietet. Deswegen wird für die weiteren Schritte die Interpolation nach Lanczos für das Resampling verwendet.

3.3.1.2 Rahmen

Befindet sich Text zu nah am Rand des Bildes, kommt es vor, dass dieser nicht richtig erkannt wird. Ebenso kann auch ein zu großer einfärbiger Rahmen am Rand des Bildes die Texterkennung stören. Bei Rahmengrößen wie in Abbildung 3.5 kommt es vor, dass Bildsektionen fälschlicherweise als „leer“ erkannt und übersprungen werden, wodurch der zu erkennende Text nicht in die Ergebnisdaten mit aufgenommen wird.

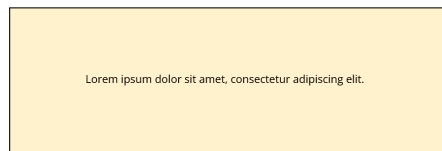


Abbildung 3.5: Ein im Verhältnis zur Bildgröße zu großer einfärbiger Rahmen

3.3.1.3 Binarisierung

Das Erzeugen eines Binärbildes ist durch Anwendung von Segmentierungsverfahren möglich. Schwellenwertverfahren (engl. *Thresholding*) bilden eine Untergruppe der Segmentierungsverfahren und werden genutzt, um Graustufenbilder Pixel für Pixel in binarisierte Ergebnisbilder mit zwei Segmenten, also einem Vordergrund und einem Hintergrund umzuwandeln. Der dazu notwendige Schwellenwert kann entweder fest definiert oder anhand von verschiedensten Algorithmen automatisch bzw. halbautomatisch ermittelt werden. Ziel ist es, durch die Binarisierung textuelle Bildinhalte unabhängig von der eigentlichen Vorder- und Hintergrundfarbe mit ausreichendem Kontrast darzustellen. Dadurch ist das Texterkennungssystem in der Lage, die einzelnen Textelemente und deren Inhalte besser zu identifizieren und zu verarbeiten. ImageMagick bietet ei-

ne Vielzahl an Thresholding-Algorithmen, deren Eignung in Abschnitt 3.2 verglichen wird.

Feste Schwellenwertmethode

Ein häufig für die Bildsegmentierung genutztes Verfahren ist die feste Schwellenwertmethode, auf Englisch auch „Fixed Thresholding“ genannt. Bei diesem Bildverarbeitungsverfahren wird ein manuell vordefinierter Grenzwert auf das gesamte Bild angewandt. Liegt ein Pixelwert über dem festgelegten Schwellenwert, gilt dieser als Teil des Vordergrunds, andernfalls als Hintergrund [15]. Somit können Objekte, also die einzelnen Buchstaben in den Grafikdateien, von ihrem Hintergrund getrennt werden.

Das fixe Thresholding benötigt durch den fest definierten Schwellenwert einen geringen Berechnungsaufwand und weist eine hohe Performance auf. Besonders bei Screenshotdateien kann es vorkommen, dass die eigentlich bunten grafischen Elemente der Benutzeroberfläche aufgrund ihrer Helligkeit über dem Schwellenwert liegen. Dadurch werden sie, genau wie der Text, als Vordergrund wahrgenommen und die gesamte Fläche wird einfärbig. Somit können jegliche Texte innerhalb dieser Fläche nicht vom Texterkennungssystem erkannt werden und die Qualität und Menge der erkannten Daten wird stark reduziert. Der Unterschied der Ergebnisdaten ist besonders im Vergleich von Abbildung 3.6 bzw. Abbildung 3.7 ersichtlich.

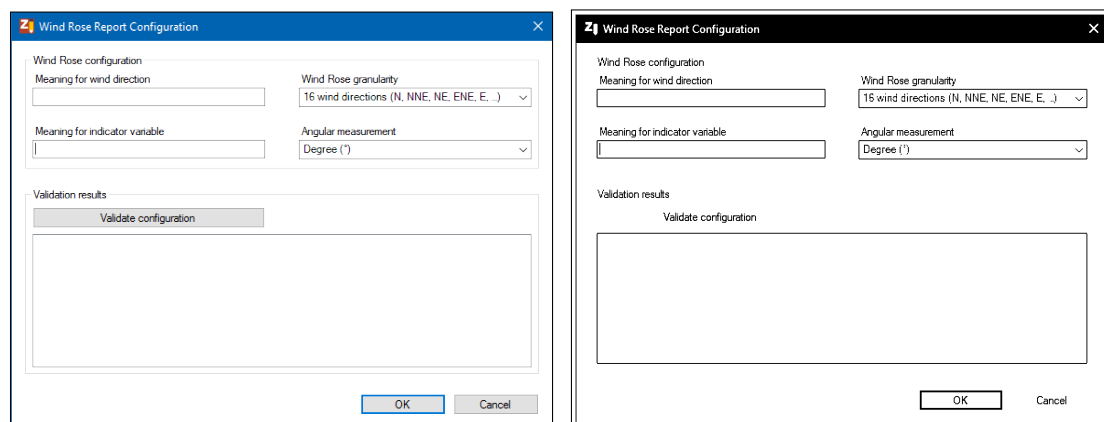


Abbildung 3.6: Anwendung des festen Schwellenwertverfahrens auf einen Beispielscreenshot. Bei einem passenden Schwellenwert und nur geringfügig verschiedenen Farbflächen ist der Textinhalt gut vom Hintergrund abgrenzbar. Der Schwellenwert im gezeigten Bild beträgt 60 %.

Adaptive Schwellenwertmethode

Die adaptive Schwellenwertmethode gehört zu den halbautomatischen Schwellenwertalgorithmen. Bei diesem Verfahren wird der Schwellenwert auf Basis der lokalen Eigenschaften eines Bildbereichs angepasst, der durch die manuell festgelegte sogenannte „Blockgröße“ definiert wird. Diese bestimmt die Seitenlänge des Rechtecks, innerhalb




Abbildung 3.7: Anwendung des festen Schwellenwertverfahrens auf einen Beispielscreenshot. Bei einem falsch gewählten Schwellenwert oder komplexen UI-Elementstrukturen ist der Text nicht erkennbar. Der Schwellenwert im gezeigten Bild beträgt 80 %.

dessen ein fester Schwellenwert ermittelt wird [15]. Durch diese dynamische Berechnung können im Gegensatz zur festen Schwellenwertmethode verschiedenfarbige Texte auf Hintergründen unterschiedlicher Helligkeit besser abgegrenzt werden und die Menge an erkanntem Text wird erhöht, wie in Abbildung 3.8 ersichtlich. Wird die Blockgröße falsch gewählt, können jedoch Artefakte auftreten, welche bei entsprechender Menge, wie im Falle von Abbildung 3.9, die Texterkennung negativ beeinflusst.

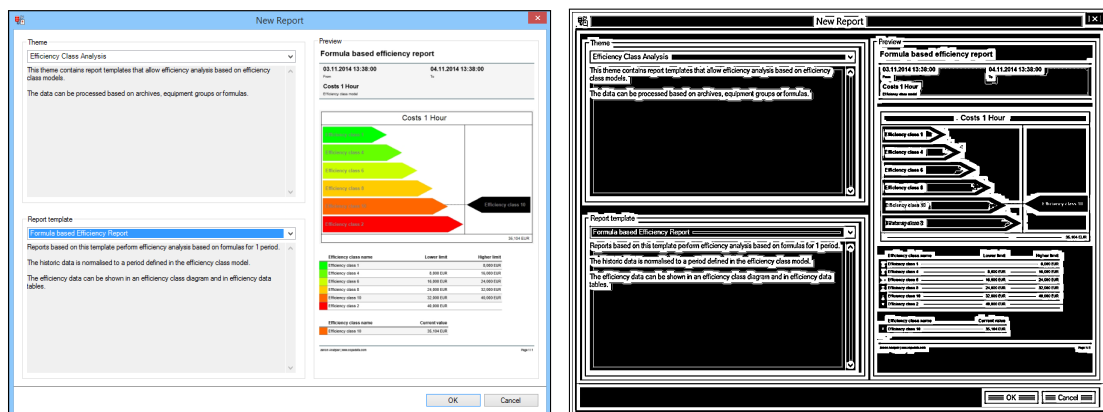


Abbildung 3.8: Anwendung der adaptiven Schwellenwertmethode auf einen Beispielscreenshot. Die Blockgröße ist gut an den Bildinhalt angepasst und alle Details bleiben erhalten. Dieses Verfahren punktet hier besonders bei den farbigen „Energy Labels“, deren Textinhalte sonst mittels keinem anderen Verfahren komplett erkannt wurden.

Dreiecks-Schwellenwertmethode

Das Dreiecks-Schwellenwertverfahren verwendet die Häufigkeitsverteilung der Helligkeitswerte eines Bildes, um einen globalen Schwellenwert zu ermitteln [21]. Werden diese Helligkeitswerte in einem Diagramm dargestellt, spricht man von einem Histogramm, wie in Abbildung 3.10 zu sehen. Für das Thresholding wird innerhalb des Histogramms eine Linie vom Höchstwert (engl. *Peak*) zum Minimum gezeichnet und die Normale mit der maximalen Länge ermittelt. Dieses Verfahren erzielt die besten Ergebnisse, wenn die




Abbildung 3.9: Anwendung der adaptiven Schwellenwertmethode auf einen Beispielscreenshot. Die bei unangepasster Blockgröße entstehenden Artefakte schränken die Funktionsweise des Texterkennungssystems deutlich ein.

zu extrahierenden Elemente Intensitätswerte aufweisen, die an der Basis des ermittelten Peaks liegen. Für Screenshots von UI-Elementen mit komplexer Struktur und farblich stark variierenden Komponenten ist es eher nicht geeignet.




Abbildung 3.10: Beispiel eines unimodalen Histogramms mit einem deutlichen Spitzenwert [33]

Schwellenwertmethode nach Otsu

Das Schwellenwertverfahren nach Otsu ermittelt einen globalen Schwellenwert durch Einteilung des Bildes in zwei Klassen (Vordergrund und Hintergrund). Dazu wird für jede Position des Schwellenwerts im Histogramm die Varianz der beiden dadurch entstehenden Klassen ermittelt. Der Schwellenwert ist dann optimal, wenn die Varianz der jeweiligen Klassen minimal ist [12]. Aufgrund dieser Eigenschaften funktioniert das Verfahren am besten, wenn das Histogramm des Bildes wie in Abbildung 3.13 eine bimodale Verteilung aufweist, also zwei klare Spitzen hat.

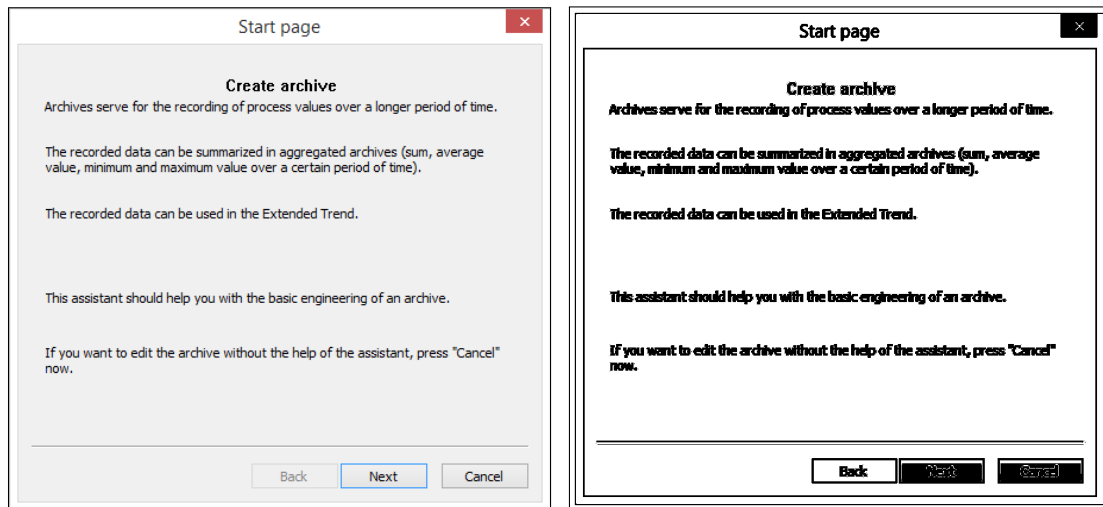


Abbildung 3.11: Anwendung der Dreiecks-Schwellenwertmethode auf einen Beispielscreenshot. Gleichen sich die Inhalte farblich, werden einige Details extrahiert. Durch kleinste Farbvariationen im Bild weicht der Schwellenwert jedoch vom Optimum ab und die Texte sind nur schwer zu erkennen.




Abbildung 3.12: Anwendung der Dreiecks-Schwellenwertmethode auf einen Beispielscreenshot. Bereits bei mäßiger Variation der Helligkeit verschwinden die ersten Details.

Enthält ein Bild jedoch starkes Hintergrundrauschen oder weist es lokale Helligkeitsunterschiede auf, wie es bei grafischen Oberflächen mit ihren unterschiedlich eingefärbten Oberflächensektionen oft der Fall ist, wird ein Schwellenwert ermittelt, der nicht immer für alle Inhalte des Bildes optimal ist. Dank der Bestimmung eines einzelnen globalen Wertes für das gesamte Bild entstehen ähnliche Probleme wie bei der fixen Schwellenwertmethode. Die Texterkennung liefert Ergebnisse mit geringem Informationsgehalt. Die Unterschiede zwischen den Ergebnissen für gut geeignete Bilder im Vergleich zu Bildern mit großen lokalen Unterschieden sind in Abbildung 3.14 bzw. Abbildung 3.15 ersichtlich.




Abbildung 3.13: Beispiel eines bimodalen Histogramms [32]




Abbildung 3.14: Anwendung der Schwellenwertmethode nach Otsu auf einen Beispiel-screenshot. Wird ein passender Schwellenwert ermittelt, lässt sich der Text gut vom Hintergrund trennen.

Schwellenwertmethode nach Kapur

Die Schwellenwertmethode nach Kapur, Sahoo und Wong zielt darauf ab, einen Schwellenwert zu finden, der die Entropie zwischen den Vorder- und Hintergrundregionen maximiert [8]. Wie in Abbildung 3.16 und Abbildung 3.17 zu sehen, liefert die Verwendung dieses Schwellenwertverfahrens gute Ergebnisse bei Bildern mit starker Varianz der Vorder- und Hintergrundkontraste bzw. einer breiten Helligkeitsverteilung.




Abbildung 3.15: Anwendung der Schwellenwertmethode nach Otsu auf einen Beispielscreenshot. Bei komplexen Strukturen im User-Interface gehen aufgrund des globalen Schwellenwerts Details verloren.




Abbildung 3.16: Anwendung der Schwellenwertmethode nach Kapur auf einen Beispielscreenshot. Trotz der vielen verwendeten Farben wird der Inhalt gut dargestellt.

3.3.2 Nachbearbeitung

Die extrahierten Textdaten aus den verarbeiteten Bilddaten werden später in einer schlagwortbasierten Suchfunktion verwendet. Um Redundanz innerhalb des Datensets zu reduzieren und falsch erkannte Ergebnisdaten zu verhindern, müssen die Ergebnisdaten der Texterkennung im Rahmen des Postprocessings weiterverarbeitet werden.

3.3.2.1 Filterung anhand der Genauigkeit

Tesseract stellt im Rahmen der Texterkennung neben den erkannten Texten auch die jeweiligen Metadaten zur Verfügung. Auch die geschätzte Genauigkeit (engl. *Confidence*) wird für jedes erkannte Wort mit angegeben. Sie bestimmt, mit welcher Sicherheit ein Texterkennungssystem das jeweilige Wort erkannt hat, wobei Wörter mit hoher Confidence eher richtig, mit niedriger Confidence eher falsch erkannt wurden.

Wie in Abbildung 3.18 gezeigt, prüft der Confidence-Filter die jeweiligen Wörter auf ihre Metadaten und verwirft jene, deren Confidence unter einem fixen Schwellenwert liegt. Je nach Einstellung bzw. „Härte“ des Filters wird die Anzahl der falsch erkannten Inhalte

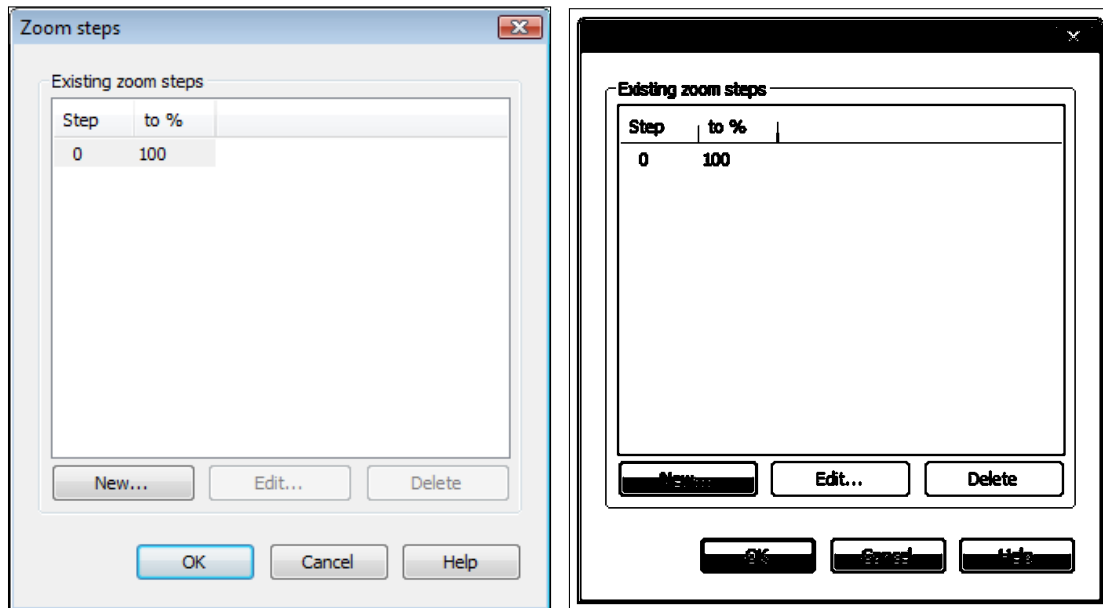


Abbildung 3.17: Anwendung der Schwellenwertmethode nach Kapur auf einen Beispiel-screenshot. Trotz der eigentlich einfach erscheinenden Oberfläche erzeugt das Verfahren Artefakte, die die Texterkennung deutlich erschweren.

innerhalb der Schlagwortmenge drastisch reduziert. Ist der Filter zu streng eingestellt, werden jedoch insgesamt weniger Worte in die Ergebnisse mit aufgenommen und es kann vorkommen, dass auch ursprünglich korrekt erkannte Wörter aufgrund eines niedrigen Confidence-Wertes verworfen werden.

```

2  {
3    "Text": "#:",
4    "Confidence": 68.34635162353516
5  },
6  {
7    "Text": "Variablendefinition",
8    "Confidence": 91.65243530273438
9  },
10 {
11   "Text": "BaER",
12   "Confidence": 0
13 },
14 {

```

```

2  {
3    "Text": "#:",
4    "Confidence": 68.34635162353516
5  },
6  {
7    "Text": "Variablendefinition",
8    "Confidence": 91.65243530273438
9  },
10 {
11   "Text": " ",
12   "Confidence": 95
13 },
14 {

```

Abbildung 3.18: Auszug aus den Ergebnisdaten der Texterkennung aus 3.3 nach der Confidence-Filterung. Alle Wörter unter dem Schwellenwert werden entfernt.

3.3.2.2 Normalisierung

Um die aus der Texterkennung gewonnenen Daten zunächst für die weitere Filterung vorzubereiten, ist es sinnvoll, die Redundanz der Daten möglichst zu reduzieren und die einzelnen Wörter zu normalisieren bzw. zu standardisieren. Beispielsweise kann durch das Umwandeln aller Textdaten in Kleinbuchstaben die Variation der Daten eingeschränkt werden, ohne jedoch für die Suche relevante Information zu verlieren. Diese Methode wurde auch in Abbildung 3.19 angewandt.

2	"#:",	2	"#:",
3	"Variablendefinition",	3	"variablendefinition",
4	" ",	4	" ",
5	" ",	5	" ",
6	" ",	6	" ",
7	" ",	7	" ",
8	" ",	8	" ",
9	" ",	9	" ",
10	" ",	10	" ",
11	" ",	11	" ",
12	" ",	12	" ",
13	" ",	13	" ",
14	"Selektieren",	14	"selektieren",

Abbildung 3.19: Auszug aus den Ergebnisdaten der Texterkennung aus 3.3 nach der Normalisierung. Alle Wörter beinhalten nun ausschließlich Kleinbuchstaben.

3.3.2.3 Vermeidung von Duplikaten

Nach der Normalisierung werden Duplikate innerhalb der erkannten Textdaten entfernt, um die Effizienz der nachfolgenden Filterverfahren zu erhöhen. In den Daten aus Abbildung 3.20 wird die Liste an erkannten Wörtern stark gekürzt und die Redundanz damit verringert. Es treten keine Duplikate mehr auf.

33	"+",	14	"doppelwort",
34	"treibervariable",	15	"treibervariable",
35	"doppelwort",	16	"variablendefinition",
36	"+",	17	"+",
37	"treibervariable",	18	"selektieren",
38	"float",	19	"#:",
39	"+",	20	"archive",
40	"treibervariable",	21	"=",
41	"string",	22	";",

Abbildung 3.20: Auszug aus den Ergebnisdaten der Texterkennung aus 3.3 nach der Duplikatentfernung.

3.3.2.4 Filterung anhand der Wortlänge

Verarbeitet das Texterkennungssystem Texte mit unregelmäßigen Abständen oder grafischen Artefakten in der Schrift, werden statt des eigentlichen Wortes fälschlicherweise oft kurze Symbolkombinationen erkannt. Um diese Kombinationen aus den Ergebnissen zu entfernen, können Zeichenketten, wie in Abbildung 3.21 gezeigt, mithilfe des Wortlängenfilters ungeachtet ihres Inhaltes verworfen werden.

Zusätzlich kann dieser Filter an die Anforderung des Zielsystems angepasst werden. So haben beispielsweise Wörter, die weniger als zwei Zeichen beinhalten, einen für die Schlagwortsuche zu geringen Informationsgehalt und werden daher entfernt.

```
14 "doppelwort",  
15 "treibervariable",  
16 "variablendefinition",  
17 "+",  
18 "selektieren",  
19 "#:",  
20 "archive",  
21 "=",  
22 ";;",
```

```
11 " ",  
12 " ",  
13 "doppelwort",  
14 "treibervariable",  
15 "variablendefinition",  
16 "selektieren",  
17 "#:",  
18 "archive",  
19 "en"
```

Abbildung 3.21: Auszug aus den Ergebnisdaten der Texterkennung aus 3.3 nach der Wortlängenfilterung. Alle Wörter, die kürzer sind als der Schwellenwert, werden aus den Ergebnisdaten entfernt.

3.3.2.5 Sprachabhängige Filterung mittels Regular Expressions

Nachdem die zu filternden Textdaten durch vorherige Schritte vorverarbeitet wurden, werden die Ergebnisdaten ein letztes Mal mithilfe von regulären Ausdrücken (engl. *Regular Expressions*) durchsucht. Aufgrund der dynamischen Erweiterbarkeit der Regular Expressions kann für jede Sprache ein individueller Filter angelegt werden, der den jeweiligen Zeichensatz beschriftet und unbekannte Sonderzeichen oder Symbole entfernt. So sind beispielsweise im Deutschen Umlaute erlaubt, während häufig auftretende, jedoch unerwünschte Symbole wie das phonetische Zeichen „æ“ oder mehrere hintereinandergereihte Leerzeichen explizit entfernt werden können. Die Anwendung des deutschen Sprachfilters wird in Abbildung 3.22 gezeigt.

7	"gewünschte",	2	"bit",
8	"das",	3	"float",
9	"string",	4	"sie",
10	" ",	5	"wort",
11	" ",	6	"byte",
12	" ",	7	"gewünschte",
13	" ",	8	"das",
14	"doppelwort",	9	"string",
15	"treibervariable",	10	"doppelwort",
16	"variablendefinition",	11	"treibervariable",
17	"+",	12	"variablendefinition",
18	"selektieren",	13	"selektieren",
19	"#:",	14	"archive",

Abbildung 3.22: Auszug aus den Ergebnisdaten der Texterkennung aus 3.3 nach der Filterung mit Regular Expressions. Findet der sprachabhängige Filter keine Treffer, wird das Wort aus den Ergebnisdaten entfernt.

Kapitel 4

Implementierung

4.1 Implementierung

4.1.1 Vergleichsdaten

Als Ausgangsdaten für die Durchführung wurde eine zufällige Auswahl an Dokumentationsscreenshots, wie in Abbildung 4.1 abgebildet, getroffen. Zusätzlich wurden auch Bilder wie in Abbildung 4.2 in die Stichprobe mit aufgenommen, die beispielsweise aufgrund ihrer Auflösung oder Kontrastverhältnisse schwer lesbar sind.




Abbildung 4.1: Ein gut für die Texterkennung geeigneter Screenshot. Die wesentlichen Inhalte weisen einen guten Kontrast zum Hintergrund auf und befinden sich in Bereichen mit gleichmäßiger Helligkeit.

Die textuellen Inhalte aller ausgewählten Bilder wurden anschließend manuell extrahiert und für den programmatischen Vergleich in einer Datei im selben Verzeichnis wie die Quellbilddatei festgehalten. Ein Beispiel dafür ist der Screenshot „zrs_ZAMS_filteralarmgroup_001“ in Abbildung 4.3, welcher insgesamt 15 verschiedene Wörter beinhaltet.





Abbildung 4.2: Ein schlecht lesbarer Screenshot. Aufgrund der vielen Symbole und der bunten Flächen stellt dieses Bild eine Herausforderung für das Texterkennungssystem dar.



```
{
  "words": [
    "group",
    "prefilter",
    "static",
    "enable",
    "alarm",
    "prefiltering",
    "machine",
    "emergency",
    "stop",
    "external",
    "failure",
    "equipment",
    "select",
    "all",
    "deselect"
  ]
}
```

Abbildung 4.3: Ein Screenshot und die daraus manuell extrahierten Schlagworte.

4.1.2 Verwendete Bibliotheken

4.1.2.1 Fremdbibliotheken

In der prototypischen Implementierung, geschrieben in der Programmiersprache C#, wurden in Referenz an die in Abschnitt 2.2 vorgestellten Technologien und Werkzeuge folgende NuGet-Bibliotheken als Basis für die Implementierung verwendet:

- **Magick.NET**
Version: 13.1.0
Lizenz: Apache-2.0
<https://www.nuget.org/packages/Magick.NET.Core>
- **Tesseract**

Version: 5.2.0
 Lizenz: Apache-2.0
<https://www.nuget.org/packages/Tesseract>

4.1.2.2 Verarbeitungsketten

Beim Entwurf des Verarbeitungssystems für die unterschiedlichen Bild- und Textverarbeitungsschritte wurde bewusst auf Flexibilität geachtet. Mithilfe von Interfaces und Builder-Methoden ist es möglich, Verarbeitungsschritte gemäß Programm 4.1 als Prozessoren (engl. *Processors*) zu definieren. So stellt beispielsweise das Normalisieren eines durch Tesseract erkannten Wortes einen Verarbeitungsschritt dar, wie in Programm 4.2 gezeigt.

```
public interface IProcessor
{
    IEnumerable Process(IEnumerable inputs);
}

public interface IProcessor<in TInput, out TOutput> : IProcessor
{
    IEnumerable<TOutput> Process(IEnumerable<TInput> inputs);

    new IEnumerable Process(IEnumerable inputs)
    {
        return Process((IEnumerable<TInput>)inputs);
    }
}
```

Programm 4.1: Auszug aus Datei „IProcessor.cs“: Schnittstelle eines Prozessors.

```
public class ToLowerProcessor
    : Processor<ScanResult, ScanResult>
{
    public override IEnumerable<ScanResult> Process(
        IEnumerable<ScanResult> inputs
    )
    {
        foreach (var kv in inputs)
        {
            kv.Word.Text = kv.Word.Text.ToLower();
            yield return kv;
        }
    }
}
```

Programm 4.2: Auszug aus Datei „ToLowerProcessor.cs“: Normalisieren als einzelner Verarbeitungsschritt.

Sollen mehrere Schritte verbunden werden, bietet das Processing-Framework die Möglichkeit, eine Verarbeitungskette aufzubauen. Gemäß der Schnittstellendefinition in Pro-

programm 4.3 können Delegates oder komplette Prozessoren dynamisch als einzelne Schritte aneinandergereiht werden. Die Typensicherheit wird durch das generische Typensystem von C# stets gewahrt.

```
public interface IProcessorChainConfiguration<TInput, TOutput>
    : IProcessorChain<TInput, TOutput>
{
    IProcessorChainConfiguration<T, TOutput, TInput, TOutput> Use<T>(
        IProcessor<TInput, T> processor);

    IProcessorChainConfiguration<T, TOutput, TInput, TOutput> Use<T>(
        Func<IEnumerable<TInput>, IEnumerable<T>> processorFunc);

    IProcessorChainConfiguration<TInput, TOutput> Complete(
        IProcessor<TInput, TOutput> processor);

    IProcessorChainConfiguration<TInput, TOutput> Complete(
        Func<IEnumerable<TInput>, IEnumerable<TOutput>> processorFunc);
}

public interface IProcessorChainConfiguration<TInput, TOutput, TInChain, TOutChain>
{
    IProcessorChainConfiguration<T, TOutput, TInChain, TOutChain> Use<T>(
        IProcessor<TInput, T> processor);

    IProcessorChainConfiguration<T, TOutput, TInChain, TOutChain> Use<T>(
        Func<IEnumerable<TInput>, IEnumerable<T>> processorFunc);

    IProcessorChain<TInChain, TOutChain> Complete(
        IProcessor<TInput, TOutput> processor);

    IProcessorChain<TInChain, TOutChain> Complete(
        Func<IEnumerable<TInput>, IEnumerable<TOutput>> processorFunc);
}
```

Programm 4.3: Auszug aus Datei „IProcessorChainConfiguration.cs“: Schnittstelle zur Konfiguration einer Verarbeitungskette

Ist die Aufbauphase abgeschlossen, kann die Verarbeitungskette, konfiguriert in Programm 4.4, gestartet werden.

Abhängig von den verwendeten Prozessoren können also Eingangsdaten jeglichen Typs, in diesem Fall Bildobjekte der Magick.NET Bibliothek oder Ergebnisdaten des Texterkennungsvorgangs dynamisch verarbeitet werden.

Bildverarbeitungskette

Für den Ablauf der Bildverarbeitung und der anschließenden Ergebnisfilterung werden die Erkenntnisse aus Kapitel 3 mithilfe des in Unterunterabschnitt 4.1.2.2 beschriebenen Processing-Frameworks angewandt. Die Resultierende Konfiguration ist in Programm 4.5 und Programm 4.6 definiert.

```
var postProcessor = new ProcessorChainConfiguration<ScanResult, ScanResult>()
    .Use(new ConfidenceFilter(50))
    .Use(new ToLowerProcessor())
    .Use(new DuplicateFilter())
    .Complete(new RegexFilter(WordRegex));

// ...

postProcessor.Process(data);
```

Programm 4.4: Auszug aus Datei „ImageViewModel.cs“: Konfiguration und Starten einer Verarbeitungskette.

Anfangen mit einem Ausgangsbild, welches über die Softwarebibliothek Magick.NET geladen wurde, beginnt die Bildverarbeitung zunächst mit dem Resampling. Falls der geladene Screenshot die Mindestauflösung von 300 dpi unterschreitet, wird es mittels Lanczos2-Verfahren, eine von Magick.NET mitgelieferte Implementierung des Lanczos2-Algorithmus mit leichter Schärfung [29], auf die Mindestauflösung vergrößert. Anschließend wird das Bild normalisiert, in Graustufen umgewandelt und jegliche Transparenz durch einen weißen Hintergrund ersetzt. Danach wird es mittels Schwellwertverfahren binarisiert. Rund um das Bild wird ein Rahmen mit einer Dicke von 10px eingefügt. Um Texterkennungsfehler durch falsche Vorder- bzw. Hintergrundfarben auszuschließen, wird das Bild gemeinsam mit einer farblich invertierten Version an das Texterkennungssystem weitergegeben.

```
var preprocessing = new ProcessorChainConfiguration<MagickImage, MagickImage>()
    .Use(new CloneImageProcessor())
    .Use(new ResizeProcessor(FilterType.Lanczos2Sharp, PixelInterpolateMethod.Mesh))
    .Use(new NormalizeProcessor())
    .Use(_thresholdProcessor)
    .Use(new AddBorderProcessor(10))
    .Use(new BinarizeProcessor())
    .Use(new NegateCloneProcessor())
    .Complete(OnPreprocessed);
```

Programm 4.5: Auszug aus Datei „EvaluationProcessor.cs“: Definition der Preprocessing-Kette.

Wurde der übergebene Screenshot vom Texterkennungssystem verarbeitet, müssen nun die Ergebnisse gefiltert werden. Dazu werden zunächst die Metadaten der einzelnen Wörter betrachtet und alle Elemente mit einer Confidence unter einem Schwellenwert von 50% verworfen. Danach werden die erkannten Texte mittels der C#-Funktion ToLower() normalisiert und anschließend auf Duplikate untersucht. Sind alle Duplikate verworfen, werden die Wörter mittels sprachabhängigen Regular Expressions – in diesem Fall gibt es gemäß den Annahmen in Unterunterabschnitt 3.1.2.2 einen Sprachfilter für Englisch und Deutsch – gefiltert.


```
var postprocessing = new ProcessorChainConfiguration<ScanResult, ScanResult>()
    .Use(new ConfidenceFilter(50))
    .Use(new ToLowerProcessor())
    .Use(new DuplicateFilter())
    .Complete(new RegexFilter(wordRegex));
```

Programm 4.6: Auszug aus Datei „EvaluationProcessor.cs“: Definition der Postprocessing-Kette.

4.1.2.3 Lookup

Die „Lookup“ Bibliothek abstrahiert das Speichern von Schlüssel-Wert-Paaren. Dabei kann flexibel zwischen verschiedenen Speicherimplementierungen gewechselt werden. So ist es beispielsweise möglich, die Werte in einer Listenstruktur im Arbeitsspeicher, in einer Datei oder – mittels der EntityFramework-Bibliothek, welche von der .NET Foundation entwickelt wird – in einer Datenbank persistent abzulegen. Unabhängig von der Ablagestruktur im Hintergrund können Lookups mittels einer gemeinsamen Schnittstelle, abgebildet in Programm 4.7, manipuliert werden.

```
public interface ILookup<TKey, TValue>
: ILookup,
IDictionary<TKey, ICollection<TValue>>,
IDisposable
{
    ICollection<TValue> Add(TKey key);

    public void Add(TKey key, TValue value);

    public void AddRange(TKey key, IEnumerable<TValue> values);

    public bool Remove(TKey key, TValue value);

    public ICollection<TValue> GetOrAdd(TKey key);
}
```

Programm 4.7: Auszug aus Datei „ILookup.cs“: Definition der gemeinsamen Schnittstelle für Lookups

4.1.2.4 OCR

Die OCR-Bibliothek beinhaltet elementare Funktionen für die Texterkennung. Sie enthält Funktionen zur Bearbeitung von Bildern mittels Magick.NET inklusive anschließender Verarbeitung mittels Tesseract. Kernkomponenten wie das Texterkennungssystem werden automatisch auf Basis der Eingabeparameter konfiguriert und die Verwendung der Ergebnisdaten in externen Programmteilen wird durch die Zurverfügungstellung von Datenmodellen für die Ergebnisdaten vereinfacht. Außerdem enthält die Bibliothek eine Reihe von vordefinierten Verarbeitungsketten bzw. Prozessoren für die Bild- und Textverarbeitung.

4.1.2.5 Automatische Berichterstellung

Mithilfe des ReportGenerator-Frameworks wird die automatische Berichterstellung für unterschiedlichste Ausgabeformate abstrahiert. Durch die mitgelieferten Schnittstellendefinitionen ist es möglich, eigene Ausgabeformate zu definieren. Der gesamte Funktionsumfang des ReportGenerators, beispielsweise das Erstellen von Tabellen oder das Anlegen und Überschriften, kann durch die Implementierung von Interfaces wie Programm 4.8 an die jeweilige Syntax und Dokumentstruktur angepasst werden.

```
public interface IDocumentGenerator : IStreamWriter
{
    IDocumentGenerator Append(string? text = default);

    IDocumentGenerator AppendLine(string? text = default);

    IDocumentGenerator AppendParagraph(string? text = default);

    IDocumentGenerator AppendHeading(int level, string text);

    IDocumentGenerator AppendTable(int columns, Action<ITableGenerator> table);

    string FormatImage(string path, IBounds? bounds = default);
}
```

Programm 4.8: Auszug aus Datei „IDocumentGenerator.cs“: Hauptschnittstelle für den ReportGenerator

4.1.3 Programmablauf

Die prototypische Implementierung besteht neben den oben genannten Komponenten aus einem ausführbaren Kommandozeilenprogramm zur Texterkennung und einem Programm zum Vergleich der Ergebnisse mit den manuell verschlagworteten Soll-Daten. Alle relevanten Daten werden in entsprechenden Ausgabeverzeichnissen festgehalten und dadurch für den jeweiligen nächsten Schritt verfügbar gemacht.

4.1.3.1 Texterkennung

Zu Beginn der Ausführung des Kommandozeilenprogramms wird für jedes zu verarbeitende Bild abhängig von den definierten Schwellenwertverfahren eine Reihe von Prozessoren angelegt. Dazu wurde der statische Teil der Bildverarbeitungskette gemäß 4.1.2.2 innerhalb der „EvaluationProcessor“ Klasse definiert, wie in Programm 4.9 auszugsweise dargestellt. Lediglich die zu evaluierenden Prozessoren für die jeweiligen Schwellenwertverfahren können außerhalb der Klasse dynamisch definiert werden. Der EvaluationProcessor legt die erzeugten Ergebnisdaten, bestehend aus den gefundenen Wörtern und zugehörigen Metadaten wie die Confidence, auf Dateiebene ab. Um überprüfen zu können, welches Bild schlussendlich an das Texterkennungssystem übergeben wurde, werden auch die verarbeiteten Bilder nach der Binarisierung gespeichert.

Ist die Erstellung der Bildbearbeitungsprozessoren abgeschlossen, wird jeder einzelne

```
private static IEnumerable<EvaluationProcessor> MakeThresholdVariations()
{
    for (int i = 4; i <= 24; i += 4)
    {
        yield return new(new ThresholdAdaptiveProcessor(i));
    }

    for (int i = 20; i <= 80; i += 10)
    {
        yield return new(new ThresholdProcessor(i));
    }

    yield return new(new AutoThresholdProcessor(AutoThresholdMethod.Kapur));
    yield return new(new AutoThresholdProcessor(AutoThresholdMethod.OTSU));
    yield return new(new AutoThresholdProcessor(AutoThresholdMethod.Triangle));
}
```

Programm 4.9: Auszug aus Datei „Program.cs“: Definition der Thresholding Prozessoren.

Prozessor über die Systembibliothek „System.Threading.Tasks“ als eigene Ausführungseinheit (engl. *Task*) gestartet. In der Kommandozeile wird anschließend der aktuelle Status jedes Tasks angezeigt. Wurden alle Tasks abgeschlossen, wird das Programm beendet.

4.1.3.2 Vergleich mit Soll-Daten

Wurden die in den jeweiligen Screenshots erkannten Textdaten abgelegt, werden diese Daten im zweiten Kommandozeilenprogramm „ReportGenerator“ nun mit den manuell verschlagworteten Daten verglichen und die Ergebnisse in einen Bericht (engl. *Report*) gespeichert.

Als zentrale Komponente für den Vergleich spielt die Berechnung der in Unterabschnitt 3.2.1 erklärten Metriken eine wesentliche Rolle. Wie in Programm 4.10 ersichtlich, wird die Distanz zwischen zwei C#-Enumerables, seien es zwei Strings oder zwei Listen, über das Verfahren nach Levenshtein berechnet.

Nach der Ermittlung der jeweiligen Distanzen auf Wort- bzw. Bildbasis werden sie mit den jeweiligen Ursprungsbildern, Prozessoren und den verwendeten Algorithmen in Bezug gesetzt. Die so aufbereiteten Ergebnisse werden anschließend an den ReportGenerator übergeben und in einen Bericht zusammengefasst.

4.2 Evaluierung

Nachdem die vorbereiteten Bilddaten an das Texterkennungssystem gemäß Abschnitt 4.1 übergeben und die Ergebnisse ermittelt wurden, werden die extrahierten Textdaten nun mit den manuell erstellten „Soll-Daten“ verglichen. Anhand der Statistik kann festgestellt werden, welche Vorgehensweise zu der besten Qualität führt. Um die Ergebnisse

```

public static double GetDistance<T>(T reference, T? hypothesis)
    where T : IEnumerable
{
    var refArr = reference.Cast<object>().ToArray();
    var hypArr = hypothesis?.Cast<object>().ToArray() ?? Array.Empty<object>();

    var distance = new int[refArr.Length + 1, hypArr.Length + 1];

    for (var x = 0; x <= refArr.Length; x++)
    {
        distance[x, 0] = x;
    }

    for (var y = 0; y <= hypArr.Length; y++)
    {
        distance[0, y] = y;
    }

    for (var x = 0; x < refArr.Length; x++)
    {
        for (var y = 0; y < hypArr.Length; y++)
        {
            var cost = Equals(refArr[x], hypArr[y]) ? 0 : 1;

            var c1 = distance[x, y] + cost; // Bottom left

            var c2 = distance[x, y + 1] + 1; // Top left
            var c3 = distance[x + 1, y] + 1; // Bottom right

            distance[x + 1, y + 1] = Min(c1, c2, c3); // Top right
        }
    }

    return distance[refArr.Length, hypArr.Length];
}

```

Programm 4.10: Auszug aus Datei „Calculator.cs“: Berechnung der Levenshtein-Distanz.

zu visualisieren, erstellt der in Unterunterabschnitt 4.1.2.5 beschriebene „ReportGenerator“ auf Basis der Bilddateinamen automatisch einen Bericht mit den Vergleichsdaten in Tabellenform. Der erstellte Bericht wird in verschiedene Kategorien unterteilt.

4.2.1 Vergleich im Detail

4.2.1.1 Processor Stats

In der Sektion „Processor Stats“, siehe Tabelle 4.1, wird die Gesamtwortfehlerrate pro Bild mit dem jeweiligen Prozessor in Verhältnis gesetzt. Anhand der Metriken ist zu erkennen, dass gewisse Bilder aufgrund ihrer Eigenschaften (niedrige Auflösung, schwierige Farbgebung, etc.) von allen Prozessoren gleichermaßen schlecht erkannt werden. Jedoch fallen auch Spezialfälle auf: So werden beispielsweise die Textdaten in den Dialog-

Knöpfen des Bilds „worldview_zoom_steps_001“ Dank eines falsch gewählten Schwellenwerts unkenntlich gemacht. Die Texterkennung schlägt fehl.

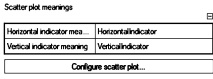
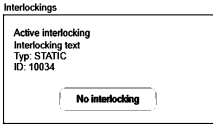



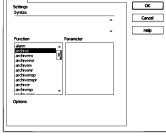


Image	Preview	Distance
zrs_ZAMS_scatter_002.png		0,09
command-pro...oup_005.png		0,11
historian_a...ent_001.png		0,19
runtime_fun...ate_002.png		0,21
editor_mult...ple_007.png		1,00
report_exam...ime_001.png		1,00
worldview_z...eps_001.png		1,00
zrs_Metadat...les_001.png		1,00

Tabelle 4.1: Auszug aus der „Processor Stats“ Tabelle im generierten Bericht. Die Eigenschaften der Originalbilder im Vergleich zu den verarbeiteten Bildern geben Aufschluss über die Arbeitsweise und Effektivität des Prozessors.

4.2.1.2 Scan Results

Die Sektion „Scan Results“ bildet den Abschluss des Detailvergleichs. Hier werden alle Verfahrenskombinationen einzeln und mit allen verfügbaren Daten aufgeführt.



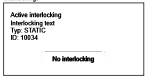





Processor	Elapsed	WER	CER (avg)	Matches	Image
ThresholdProcessor(30%)	0,6ms	0,0%	0,00	9 / 9	
ThresholdProcessor(40%)	0,6ms	0,0%	0,00	9 / 9	
ThresholdProcessor(70%)	0,7ms	0,0%	0,00	9 / 9	
ThresholdProcessor(60%)	1,1ms	0,0%	0,00	9 / 9	
ThresholdAd...ssor(12_12)	0,5ms	77,8%	3,00	2 / 9	
ThresholdAd...ssor(04_04)	1,0ms	88,9%	3,22	1 / 9	
ThresholdAd...ssor(08_08)	0,6ms	100,0%	5,89	0 / 9	
AutoThresho...r(Triangle)	12,8ms	100,0%	5,89	0 / 9	

Tabelle 4.2: Auszug aus der „Scan Results“ Tabelle im generierten Bericht. Für jede Ausgabedatei werden sämtliche Statistiken aufgelistet.

4.2.2 Prozessoren im Überblick

Neben dem Detailvergleich beinhaltet der generierte Bericht auch die „Processing Summary“. Diese Kategorie zeigt eine kurze Übersicht aller Ergebnisse. Je nach Rubrik wird jeweils der Median bzw. Durchschnitt der Character Error Rate und Word Error Rate berechnet.

Auf Basis der Daten in Tabelle 4.4, Tabelle 4.5 und Tabelle 4.6 lässt sich der Gesamterfolg der Bildvorbereitung bzw. der darauf folgenden Filterung feststellen.

Beispielsweise eignet sich die Dreiecks-Schwellenwertmethode, wie in Abbildung 3.3.1.3 vermutet, nicht für die Texterkennung. In der Detailübersicht zeigt sich, dass für die Bilder oft ein Schwellenwert gewählt wurde, der die Texterkennung unmöglich macht. Bei Anwendung des fixen Schwellenwertverfahrens werden mit dem richtigen Schwellenwert

Processor	10034	active	id	interlocking	...	text	typ
ThresholdProcessor(30%)	10034	active	id	interlocking	...	text	typ
ThresholdProcessor(40%)	10034	active	id	interlocking	...	text	typ
ThresholdProcessor(70%)	10034	active	id	interlocking	...	text	typ
ThresholdProcessor(60%)	10034	active	id	interlocking	...	text	typ
ThresholdAd...ssor(12_12)	no	no	no	interlocking	...	no	no
ThresholdAd...ssor(04_04)	text	text	text	interlockings'	...	text	text
ThresholdAd...ssor(08_08)	-	-	-	-	...	-	-
AutoThresho...r(Triangle)	-	-	-	-	...	-	-

Tabelle 4.3: Auszug aus der „Scan Results“ Tabelle im generierten Bericht. Neben der numerischen Statistik erfolgt zudem ein Vergleich der tatsächlichen Inhalte mit den erkannten Wörtern. „-“ steht hierbei für ein nicht erkanntes Wort.

durchschnittlich sehr gute Ergebnisse erzielt bzw. beim Verfahren nach Otsu oft ein geeigneter Schwellenwert gewählt, wodurch ein gutes Ausgangsbild für die Texterkennung entsteht.

Während die Fehlerquoten der Texterkennung mit Vorbereitung der Daten die der Texterkennung ohne Vorbereitung in den meisten Fällen unterbieten, ist das Ergebnis insgesamt unzufriedenstellend. Selbst bei Verwendung des fixen Thresholdingverfahrens mit einem Schwellenwert von 40 % werden durchschnittlich Ergebnisse mit einer Wortfehlerrate von mindestens 46 % bzw. 1,5 falsch erkannten Zeichen pro Wort erreicht. Die relativ hohe Standardabweichung von 26 % lässt auf eine hohe Streuung der Ergebnisdaten, also unregelmäßig gute Erfolge schließen.

Processor	Error	Deviation
ThresholdProcessor(40%)	46,04%	26,36%
ThresholdProcessor(30%)	46,84%	28,66%
AutoThresholdProcessor(OTSU)	48,76%	33,26%
ThresholdProcessor(50%)	49,95%	31,09%
ThresholdProcessor(70%)	49,96%	29,32%
...
ThresholdAdaptiveProcessor(12_12)	70,85%	24,37%
ThresholdAdaptiveProcessor(16_16)	71,32%	26,39%
ThresholdAdaptiveProcessor(08_08)	73,94%	22,37%
AutoThresholdProcessor(Triangle)	91,24%	15,16%
ThresholdAdaptiveProcessor(04_04)	94,55%	6,38%

Tabelle 4.4: Auszug aus der „Processing Summary“ Tabelle im generierten Bericht: Auflistung der Verfahren mit den durchschnittlich besten und schlechtesten Ergebnissen auf Basis der Word Error Rate. Die jeweilige Verarbeitungsmethode ist in der Spalte „Processor“ zu finden, die Wortfehlerrate und die Standardabweichung in „Time“ und „Deviation“.

Processor	Changes	Deviation
ThresholdProcessor(40%)	1,55	2,39
ThresholdProcessor(30%)	1,74	2,75
ThresholdProcessor(50%)	1,93	2,72
ThresholdProcessor(70%)	2,15	2,97
AutoThresholdProcessor(OTSU)	2,15	3,06
...
ThresholdAdaptiveProcessor(24_24)	3,00	3,18
ThresholdAdaptiveProcessor(08_08)	3,17	3,07
ThresholdAdaptiveProcessor(16_16)	3,22	3,15
AutoThresholdProcessor(Triangle)	4,71	3,22
ThresholdAdaptiveProcessor(04_04)	4,87	2,88

Tabelle 4.5: Auszug aus der „Processing Summary“ Tabelle im generierten Bericht: Auflistung der Verfahren mit den durchschnittlich besten und schlechtesten Ergebnissen auf Basis der Character Error Rate. Die jeweilige Verarbeitungsmethode ist in der Spalte „Processor“ zu finden, die Zeichenfehlerrate und die Standardabweichung in „Time“ und „Deviation“.

Processor	Time	Deviation
ThresholdAdaptiveProcessor(16_16)	0,49ms	0,28ms
ThresholdAdaptiveProcessor(20_20)	0,59ms	0,36ms
ThresholdAdaptiveProcessor(12_12)	0,59ms	0,28ms
ThresholdAdaptiveProcessor(24_24)	0,62ms	0,19ms
AutoThresholdProcessor(Kapur)	0,62ms	0,06ms
...
ThresholdAdaptiveProcessor(04_04)	0,88ms	0,11ms
ThresholdProcessor(50%)	0,95ms	0,64ms
AutoThresholdProcessor(Triangle)	1,09ms	2,50ms
ThresholdProcessor(20%)	1,58ms	4,22ms
ThresholdProcessor(40%)	1,70ms	0,47ms

Tabelle 4.6: Auszug aus der „Processing Summary“ Tabelle im generierten Bericht: Auflistung der Verfahren mit den durchschnittlich besten und schlechtesten Ergebnissen auf Basis der Laufzeit. Die jeweilige Verarbeitungsmethode ist in der Spalte „Processor“ zu finden, die Laufzeit und die Standardabweichung in „Time“ und „Deviation“.

Kapitel 5

Zusammenfassung

Im Rahmen dieser Bachelorarbeit wurde sich intensiv mit der Anwendung von optischer Texterkennung für die Verschlagwortung von Oberflächenscreenshots auseinandergesetzt. Das Ziel, eine Vorgehensweise für die automatisierte Verschlagwortung von Bilddateien zu entwickeln und die Anwendbarkeit verschiedener Algorithmen zur Bildbearbeitung und Texterkennung zu evaluieren, wurde erreicht. Insgesamt wurden die Grundlagen moderner Bildverarbeitung bzw. der Funktionsweise von Texterkennungssystemen aufgearbeitet. Das Ergebnis ist ein universelles System zur Analyse der Vergleichswerte, das auch die Integration weiterer Algorithmen ermöglicht. Dies erlaubt eine kontinuierliche Verbesserung und Anpassung des Texterkennungssystems an neue Anforderungen.

Aufgrund der Auswahl und Parametrisierung der ersten Tests beträgt die resultierende Fehlerrate in etwa 40%. Nach Abschluss der Bachelorarbeit wird es jedoch weitere Optimierungsversuche geben. Das nächste Ziel ist es, eine Wortfehlerrate von 20% nicht zu überschreiten, um eine zuverlässige Erkennung der Texte zu gewährleisten. Dazu werden weitere Bildbearbeitungsmethoden, beispielsweise Kantendetektoren, in Verbindung mit sogenanntem „Fuzzy Matching“ für die Erkennung der Schlagworte verwendet. Ebenso gibt es unter Verwendung der bereits implementierten Algorithmen noch Verbesserungspotential. Beispielsweise könnten mehrfach gefundene Wörter, die in der aktuellen Version des Prototyps einfach verworfen werden, zur Ermittlung der Wichtigkeit eines Schlagwortes genutzt werden.

Nach Abschluss der Optimierungsversuche wird das gewonnene Wissen weiter in den Screenshot-Manager einfließen und die Texterkennungsfunktionalität in das Programm integriert. Die gefundenen mehrsprachigen Schlagworte werden in Zukunft für jedes Bild ermittelt und in einer Datenbank abgelegt, um ein einfaches und effizientes Suchen innerhalb der Anwendung zu ermöglichen.

Abbildungsverzeichnis

3.1	Beispielhafte Auswahl typischer Dialogscreenshots.	6
3.2	Ein optimales Ergebnisbild. Jegliche farblichen Flächen wurden durch die Bildverarbeitung entfernt. Übrig bleibt klar lesbarer Text mit einem hohen Kontrast zum Hintergrund.	6
3.3	Auszug aus den ungefilterten Ergebnisdaten bei Durchführung der Texterkennung in dem gezeigten Screenshot.	7
3.4	Ein Vergleich unterschiedlicher Resampling-Filter. Durch die Aufteilung der Fehler auf mehrere Pixel bleiben Details und Konturen bei Anwendung des Lanczos-Filters vergleichsweise gut erhalten und der Text ist gut lesbar.	11
3.5	Ein im Verhältnis zur Bildgröße zu großer einfärbiger Rahmen	11
3.6	Anwendung des festen Schwellenwertverfahrens auf einen Beispielscreenshot. Bei einem passenden Schwellenwert und nur geringfügig verschiedenen Farbflächen ist der Textinhalt gut vom Hintergrund abgrenzbar. Der Schwellenwert im gezeigten Bild beträgt 60 %.	12
3.7	Anwendung des festen Schwellenwertverfahrens auf einen Beispielscreenshot. Bei einem falsch gewählten Schwellenwert oder komplexen UI-Elementstrukturen ist der Text nicht erkennbar. Der Schwellenwert im gezeigten Bild beträgt 80 %.	13
3.8	Anwendung der adaptiven Schwellenwertmethode auf einen Beispielscreenshot. Die Blockgröße ist gut an den Bildinhalt angepasst und alle Details bleiben erhalten. Dieses Verfahren punktet hier besonders bei den farbigen „Energy Labels“, deren Textinhalte sonst mittels keinem anderen Verfahren komplett erkannt wurden.	13
3.9	Anwendung der adaptiven Schwellenwertmethode auf einen Beispielscreenshot. Die bei unangepasster Blockgröße entstehenden Artefakte schränken die Funktionsweise des Texterkennungssystems deutlich ein.	14
3.10	Beispiel eines unimodalen Histogramms mit einem deutlichen Spitzenwert [33]	14
3.11	Anwendung der Dreiecks-Schwellenwertmethode auf einen Beispielscreenshot. Gleichen sich die Inhalte farblich, werden einige Details extrahiert. Durch kleinste Farbvariationen im Bild weicht der Schwellenwert jedoch vom Optimum ab und die Texte sind nur schwer zu erkennen.	15

3.12	Anwendung der Dreiecks-Schwellenwertmethode auf einen Beispielscreenshot. Bereits bei mäßiger Variation der Helligkeit verschwinden die ersten Details.	15
3.13	Beispiel eines bimodalen Histogramms [32]	16
3.14	Anwendung der Schwellenwertmethode nach Otsu auf einen Beispielscreenshot. Wird ein passender Schwellenwert ermittelt, lässt sich der Text gut vom Hintergrund trennen.	16
3.15	Anwendung der Schwellenwertmethode nach Otsu auf einen Beispielscreenshot. Bei komplexen Strukturen im User-Interface gehen aufgrund des globalen Schwellenwerts Details verloren.	17
3.16	Anwendung der Schwellenwertmethode nach Kapur auf einen Beispielscreenshot. Trotz der vielen verwendeten Farben wird der Inhalt gut dargestellt.	17
3.17	Anwendung der Schwellenwertmethode nach Kapur auf einen Beispielscreenshot. Trotz der eigentlich einfach erscheinenden Oberfläche erzeugt das Verfahren Artefakte, die die Texterkennung deutlich erschweren. . .	18
3.18	Auszug aus den Ergebnisdaten der Texterkennung aus 3.3 nach der Confidence-Filterung. Alle Wörter unter dem Schwellenwert werden entfernt.	18
3.19	Auszug aus den Ergebnisdaten der Texterkennung aus 3.3 nach der Normalisierung. Alle Wörter beinhalten nun ausschließlich Kleinbuchstaben.	19
3.20	Auszug aus den Ergebnisdaten der Texterkennung aus 3.3 nach der Duplikatentfernung.	19
3.21	Auszug aus den Ergebnisdaten der Texterkennung aus 3.3 nach der Wortlängenfilterung. Alle Wörter, die kürzer sind als der Schwellenwert, werden aus den Ergebnisdaten entfernt.	20
3.22	Auszug aus den Ergebnisdaten der Texterkennung aus 3.3 nach der Filterung mit Regular Expressions. Findet der sprachabhängige Filter keine Treffer, wird das Wort aus den Ergebnisdaten entfernt.	21
4.1	Ein gut für die Texterkennung geeigneter Screenshot. Die wesentlichen Inhalte weisen einen guten Kontrast zum Hintergrund auf und befinden sich in Bereichen mit gleichmäßiger Helligkeit.	22
4.2	Ein schlecht lesbarer Screenshot. Aufgrund der vielen Symbole und der bunten Flächen stellt dieses Bild eine Herausforderung für das Texterkennungssystem dar.	23
4.3	Ein Screenshot und die daraus manuell extrahierten Schlagworte.	23

Tabellenverzeichnis

4.1	Auszug aus der „Processor Stats“ Tabelle im generierten Bericht. Die Eigenschaften der Originalbilder im Vergleich zu den verarbeiteten Bildern geben Aufschluss über die Arbeitsweise und Effektivität des Prozessors.	31
4.2	Auszug aus der „Scan Results“ Tabelle im generierten Bericht. Für jede Ausgabedatei werden sämtliche Statistiken aufgelistet.	32
4.3	Auszug aus der „Scan Results“ Tabelle im generierten Bericht. Neben der numerischen Statistik erfolgt zudem ein Vergleich der tatsächlichen Inhalte mit den erkannten Wörtern. „-“ steht hierbei für ein nicht erkanntes Wort.	33
4.4	Auszug aus der „Processing Summary“ Tabelle im generierten Bericht: Auflistung der Verfahren mit den durchschnittlich besten und schlechtesten Ergebnissen auf Basis der Word Error Rate. Die jeweilige Verarbeitungsmethode ist in der Spalte „Processor“ zu finden, die Wortfehlerrate und die Standardabweichung in „Time“ und „Deviation“.	33
4.5	Auszug aus der „Processing Summary“ Tabelle im generierten Bericht: Auflistung der Verfahren mit den durchschnittlich besten und schlechtesten Ergebnissen auf Basis der Character Error Rate. Die jeweilige Verarbeitungsmethode ist in der Spalte „Processor“ zu finden, die Zeichenfehlerrate und die Standardabweichung in „Time“ und „Deviation“.	34
4.6	Auszug aus der „Processing Summary“ Tabelle im generierten Bericht: Auflistung der Verfahren mit den durchschnittlich besten und schlechtesten Ergebnissen auf Basis der Laufzeit. Die jeweilige Verarbeitungsmethode ist in der Spalte „Processor“ zu finden, die Laufzeit und die Standardabweichung in „Time“ und „Deviation“.	34

Quellenverzeichnis

Literatur

- [1] AMAM Asif u. a. „An overview and applications of optical character recognition“. *Int. J. Adv. Res. Sci. Eng* 3.7 (2014) (siehe S. 3).
- [2] KR1442 Chowdhary und KR Chowdhary. „Natural language processing“. *Fundamentals of artificial intelligence* (2020) (siehe S. 3).
- [3] Kenneth W. Church und Lisa F. Rau. „Commercial Applications of Natural Language Processing“. *Commun. ACM* 38.11 (1995). DOI: 10.1145/219717.219778 (siehe S. 3).
- [4] Line Eikvil. „Optical character recognition“. *citeseer.ist.psu.edu/142042.html* 26 (1993) (siehe S. 3).
- [5] Urvashi Gupta und Rohit Sharma. „Comparison of Different Cloud Computing Platforms for Data Analytics“. In: Sep. 2023. DOI: 10.1007/978-981-99-3716-5_7 (siehe S. 3).
- [6] Noor Islam Islam. „A survey on optical character recognition systems“. *arXiv preprint arXiv:1710.05703* (2017) (siehe S. 3).
- [7] Krishna Prakash Kalyanathaya, D Akila und P Rajesh. „Advances in natural language processing: a survey of current research trends, development tools and industry applications“. *International Journal of Recent Technology and Engineering* 7.5C (2019) (siehe S. 3).
- [8] Jagat Narain Kapur, Prasanna K Sahoo und Andrew KC Wong. „A new method for gray-level picture thresholding using the entropy of the histogram“. *Computer vision, graphics, and image processing* 29.3 (1985) (siehe S. 16).
- [9] Romain Karpinski, Devashish Lohani und Abdel Belaid. „Metrics for complete evaluation of ocr performance“. In: *IPCV'18-The 22nd Int'l Conf on Image Processing, Computer Vision, & Pattern Recognition*. 2018 (siehe S. 7–9).
- [10] Levenshtein. „Binary codes capable of correcting deletions, insertions, and reversals“. In: (Siehe S. 8, 9).
- [11] Lily Rojabiyati Mursari und Antoni Wibowo. „The effectiveness of image pre-processing on digital handwritten scripts recognition with the implementation of OCR Tesseract“. *Computer Engineering and Applications Journal* 10.3 (2021) (siehe S. 5).

- [12] Nobuyuki Otsu. „A threshold selection method from gray-level histograms“. *IEEE transactions on systems, man, and cybernetics* 9.1 (1979) (siehe S. 14).
- [13] Youngja Park u. a. „An empirical analysis of word error rate and keyword error rate.“ In: *Interspeech*. Bd. 2008. 2008 (siehe S. 8, 9).
- [14] Smith R. „An Overview of the Tesseract OCR Engine“. In: 2007. URL: <https://ieeexplore.ieee.org/document/4376991> (besucht am 12.02.2024) (siehe S. 4).
- [15] Prasanna K Sahoo, SAKC Soltani und Andrew KC Wong. „A survey of thresholding techniques“. *Computer vision, graphics, and image processing* 41.2 (1988) (siehe S. 12, 13).
- [16] Dan Sporici, Elena Cuşnir und Costin-Anton Boianu. „Improving the accuracy of Tesseract 4.0 OCR engine using convolution-based preprocessing“. *Symmetry* 12.5 (2020) (siehe S. 5).
- [17] Xiang Tong und David A Evans. „A statistical approach to automatic OCR error correction in context“. In: *Fourth workshop on very large corpora*. 1996 (siehe S. 8).
- [18] William Ughetta und Brian W. Kernighan. „The Old Bailey and OCR: Benchmarking AWS, Azure, and GCP with 180,000 Page Images“. English (US). In: Association for Computing Machinery, Inc, Sep. 2020. DOI: 10.1145/3395027.3419595 (siehe S. 3).
- [19] Ye-Yi Wang, Alex Acero und Ciprian Chelba. „Is word error rate a good indicator for spoken language understanding accuracy“. In: *2003 IEEE workshop on automatic speech recognition and understanding (IEEE Cat. No. 03EX721)*. IEEE. 2003 (siehe S. 8).
- [20] W John Wilbur und Karl Sirotkin. „The automatic identification of stop words“. *Journal of information science* 18.1 (1992) (siehe S. 7).
- [21] Gregory W Zack, William E Rogers und Samuel A Latt. „Automatic measurement of sister chromatid exchange frequency.“ *Journal of Histochemistry & Cytochemistry* 25.7 (1977) (siehe S. 13).
- [22] *Amazon Textract - Homepage*. eng. 23. Mai 2023. URL: <https://aws.amazon.com/textract> (besucht am 12.02.2024) (siehe S. 3).
- [23] *Amazon Textract - Pricing*. eng. 23. Mai 2023. URL: <https://aws.amazon.com/textract/pricing/> (besucht am 12.02.2024) (siehe S. 4).
- [24] *Azure AI Vision - Homepage*. eng. 23. Mai 2023. URL: <https://azure.microsoft.com/en-us/products/ai-services/ai-vision> (besucht am 12.02.2024) (siehe S. 3).
- [25] *Azure AI Vision - Pricing*. eng. 23. Mai 2023. URL: <https://azure.microsoft.com/en-gb/pricing/details/cognitive-services/computer-vision/> (besucht am 12.02.2024) (siehe S. 4).
- [26] *COPA-DATA zenon - Homepage*. eng. 23. Mai 2023. URL: <https://www.copadata.com/en/product/zenon-software-platform-for-industrial-automation-energy-automation/> (besucht am 12.02.2024) (siehe S. 1).
- [27] *Google Cloud Vision - Homepage*. eng. 23. Mai 2023. URL: <https://cloud.google.com/vision> (besucht am 12.02.2024) (siehe S. 3).

- [28] *Google Cloud Vision - Pricing*. eng. 23. Mai 2023. URL: <https://cloud.google.com/vision/pricing> (besucht am 12.02.2024) (siehe S. 4).
- [29] *ImageMagick Homepage*. eng. 23. Mai 2023. URL: <https://www.imagemagick.org/> (besucht am 12.02.2024) (siehe S. 4, 26).
- [30] *IronOCR for .NET - Homepage*. eng. 23. Mai 2023. URL: <https://ironsoftware.com/csharp/ocr/> (besucht am 12.02.2024) (siehe S. 3).
- [31] *Tesseract Documentation*. eng. 23. Mai 2023. URL: <https://tesseract-ocr.github.io/> (besucht am 12.02.2024) (siehe S. 4, 5, 10).

Medien

- [32] Wikimedia Commons. *Example of a histogram exhibiting bimodality*. 2014. URL: <https://commons.wikimedia.org/wiki/File:Bimodal-histogram.png> (besucht am 12.02.2024) (siehe S. 16).
- [33] Wikimedia Commons. *Histogram of tips given in a restaurant*. 2014. URL: <https://commons.wikimedia.org/wiki/File:Tips-histogram1.png> (besucht am 12.02.2024) (siehe S. 14).