

# Automatisierte Detektion und Extraktion von Elektroschrott-Komponenten mit Methoden der Bildverarbeitung und des maschinellen Lernens im Hinblick auf Tantal-Recycling

Dissertation

zur Erlangung des Doktorgrades  
der Naturwissenschaften  
(Dr. rer. nat.)

vorgelegt von

**Johannes Rücker, M.Eng.**

betreut von

Prof. Dr. P. J. Klar  
I. Physikalisches Institut  
Justus-Liebig-Universität Gießen  
**Erstgutachter**

Prof. Dr.-Ing. U. Bochtler  
Fakultät Ingenieurwissenschaften  
Hochschule Aschaffenburg  
**Zweitgutachter**

September 2017



# Zusammenfassung

In der vorliegenden Arbeit werden die Entwicklung und der Aufbau eines Systems vorgestellt, das im Rahmen des Elektroschrottrecyclings zum Einsatz kommen kann. Diese Anlage wurde mit dem Ziel entwickelt, spezielle Bauteile auf Leiterplatten mit einem hohen Anteil an Hochtechnologie-Metallen automatisiert zu detektieren, um sie im Folgenden von der Platine zu lösen und einer gesonderten Verwertung zuzuführen. Der aufgebaute Prototyp besteht aus einem Erkennungs- und einem Extraktionssystem.

Im Erkennungssystem werden die Leiterplatten mit bildgebenden Sensoren vermessen, die mit einer leistungsfähigen Recheneinheit zur Auswertung der Messdaten verbunden sind. Zum Einsatz kommen eine Hochgeschwindigkeitskamera und ein industrieller Laserscanner in Verbindung mit einem Förderband. Die anfallenden Daten werden mittels Gigabit-Ethernet an den Hochleistungsrechner gesendet und anschließend mit Verfahren des maschinellen Lernens und der Bildverarbeitung ausgewertet. Die Messdaten werden dazu mit einer selbst entwickelten Verarbeitungskette zuerst segmentiert und anschließend klassifiziert. Um hohe Detektionsraten sicherzustellen, wurden moderne Algorithmen wie „convolutional neural networks“ und „random forests“ untersucht und eingesetzt. Zur Evaluierung der Erkennungsrate wurde eine Datenbank mit mehr als 13000 Bauteilen aufgenommen und ausgewertet. Insgesamt konnte damit für fünf Klassen eine Segmentierungsrate von 83 % und eine Detektionsrate von bis zu 95,5 % erreicht werden. Das vollständige Softwaresystem auf der Recheneinheit umfasst etwa 25000 Zeilen C++-Code und 15000 Zeilen MATLAB-Code.

Die Anlage zur Extraktion besteht aus einem 6-Achsen-Knickarm-Roboter, für den ein spezieller Aufsatz zur Extraktion von integrierten Schaltungen und Tantalkondensatoren entwickelt wurde. Die Extraktion erfolgt dabei wahlweise mittels Heißluft und Absaugung oder mittels Heißluft und Druckluft. Die Evaluierung der Extraktion wurde anhand von 47 Leiterplatten des gleichen Typs vorgenommen. Insgesamt ließen sich mit geeigneten Parametern bis zu 75 % der Tantalkondensatoren und 100 % der integrierten Schaltungen vollautomatisch entfernen. Außerdem wurde eine Extraktion mittels Laserschnitt überprüft und darauf aufbauend eine Wirtschaftlichkeitsanalyse für die Pilotanlage und eine mögliche Industrieumsetzung durchgeführt. Konkret berechnet wurde dabei die Wirtschaftlichkeit der Detektion und Extraktion von Tantalkondensatoren, die nach Literaturangaben über einen hohen Gehalt an Tantal verfügen.



# Abkürzungen und Nomenklatur

## Abkürzungen

|            |   |
|------------|---|
| A-KAZE     | accelerated KAZE                                    |
| AUC        | area under the curve                                |
| BGA        | ball grid array                                     |
| BLOB       | binary large object                                 |
| CCD        | charge-coupled device                               |
| CMOS       | complementary metal oxide semiconductor             |
| CNN        | convolutional neural network                        |
| CPU        | central processing unit                             |
| DT         | decision tree                                       |
| EAG        | Elektro- und Elektronik-Altgeräte                   |
| FP         | false positive                                      |
| FPGA       | field programmable gate array                       |
| FPS        | frames per second                                   |
| GFSK       | Geometrische, farbliche und statistische Kenngrößen |
| GPU        | graphics processing unit                            |
| GT         | ground truth  |
| HOG        | histogram of oriented gradients                     |
| HT-Metalle | Hochtechnologie-Metalle                             |
| IC         | integrated circuit                                  |
| KAZE       | jap. Wind, rotationsinvariantes Merkmal             |
| KKT        | Karush-Kuhn-Tucker-Bedingungen                      |
| KNN        | Künstliches neuronales Netz                         |
| LBP        | local binary pattern                                |
| LED        | light-emitting diode                                |
| MLP        | multilayer perceptron                               |
| MSAC       | M-estimator sample consensus                        |
| NIR        | Nahes Infrarot                                      |
| OCR        | optical character recognition                       |
| PCA        | principal component analysis                        |
| PCB        | printed circuit board                               |

|        |  |
|--------|--|
| R-CNN  | region-based CNN                           |
| RANSAC | random sample consensus                    |
| RBF    | Radiale Basisfunktion                      |
| ReLU   | rectified linear unit                      |
| RF     | random forest                              |
| ROC    | receiver operating characteristics         |
| SMOTE  | synthetic minority over-sampling technique |
| SMT    | surface-mount technology                   |
| SVM    | support vector machine                     |
| THT    | through-hole technology                    |
| TOF    | time of flight                             |
| TP     | true positive                              |

## Nomenklatur

|  |   |
|--|---|
| $\forall$                                | Für alle  |
| $\ \mathbf{a}\ $                         | Euklidische Norm von $\mathbf{a}$               |
| $\langle \mathbf{a}, \mathbf{b} \rangle$ | Skalarprodukt von $\mathbf{a}$ und $\mathbf{b}$ |
| $\mathbf{A}$                             | Darstellung einer Matrix                        |
| $\mathbf{A}^{-1}$                        | Inverse von $\mathbf{A}$                        |
| $\mathbf{a}$                             | Darstellung eines Vektors                       |
| $\mathbf{a}^T$                           | $\mathbf{a}$ transponiert                       |
| $c, C$                                   | Darstellung eines eindimensionalen Werts        |

# Inhaltsverzeichnis

|  |            |
|--|------------|
| <b>Zusammenfassung</b>   | <b>iii</b> |
| <b>Abkürzungen und Nomenklatur</b>   | <b>v</b>   |
| <b>Inhaltsverzeichnis</b>  | <b>vii</b> |
| <b>1 Einleitung und Motivation</b>   | <b>1</b>   |
| 1.1 Verfahren zur automatisierten Identifikation von Komponenten . . . . .   | 2          |
| 1.2 Zielstellung und vergleichbare Ansätze . . . . .                         | 5          |
| 1.3 Aufbau der Arbeit . . . . .  | 7          |
| <b>2 Theoretische Grundlagen</b>   | <b>9</b>   |
| 2.1 Aufbau eines Bildverarbeitungssystems . . . . .                          | 9          |
| 2.2 Sensoren zur Vermessung von Leiterplattenkomponenten . . . . .           | 10         |
| 2.2.1 Bildgebende Verfahren . . . . .  | 10         |
| 2.2.2 Verfahren auf Basis multispektraler Aufnahmen . . . . .                | 14         |
| 2.3 Algorithmen in der Vorverarbeitung und Segmentierung . . . . .           | 15         |
| 2.3.1 Kalibration von Bilddaten . . . . .                                    | 15         |
| 2.3.2 Morphologische Operationen zur Binärdatenoptimierung . . . . .         | 15         |
| 2.3.3 Detektion von zusammenhängenden Objekten in Binärdaten . . . . .       | 17         |
| 2.3.4 Schätzung von Modellparametern mittels zufälliger Stichprobe . . . . . | 19         |
| 2.4 Verfahren zur Merkmalerstellung . . . . .                                | 20         |
| 2.5 Algorithmen zur Klassifizierung . . . . .                                | 23         |
| 2.5.1 Grundlagen zur Klassifizierung . . . . .                               | 23         |
| 2.5.2 Support Vector Machines . . . . .                                      | 25         |
| 2.5.3 Künstliche neuronale Netze . . . . .                                   | 30         |
| 2.5.4 Convolutional Neural Network . . . . .                                 | 35         |
| 2.5.5 Random Forest . . . . .  | 36         |
| 2.5.6 Verfahren zur Bewertung einzelner Klassifikationsergebnisse . . . . .  | 39         |
| <b>3 Analyse des Elektroschrotts</b>   | <b>43</b>  |
| <b>4 Experimenteller Aufbau einer Detektionsanlage</b>                       | <b>47</b>  |
| 4.1 Zentrale Steuerungseinheit . . . . .                                     | 47         |
| 4.2 Kamera AVT Prosilica GT2050C . . . . .                                   | 49         |
| 4.3 Laserscanner LMI Gocator 2370 . . . . .                                  | 50         |
| 4.4 Spektroskopiehalbkugel . . . . .   | 51         |

|          |   |            |
|----------|---|------------|
| <b>5</b> | <b>Echtzeitfähiges Softwaresystem zur Bauteilerkennung</b>  | <b>53</b>  |
| 5.1      | Systemaufbau . . . . .                                      | 53         |
| 5.1.1    | Vorverarbeitung . . . . .                                   | 54         |
| 5.1.2    | Segmentierung . . . . .                                     | 56         |
| 5.1.3    | Merkmalerstellung und untersuchte Merkmale . . . . .        | 59         |
| 5.1.4    | Klassifizierung . . . . .                                   | 65         |
| 5.1.5    | Erweiterung der Datenbank um künstliche Daten . . . . .     | 69         |
| 5.2      | Evaluation der Echtzeitfähigkeit . . . . .                  | 70         |
| <b>6</b> | <b>Pilotanlage zur Bauteilextraktion</b>                    | <b>73</b>  |
| 6.1      | Robotergestützte Bauteilextraktion . . . . .                | 73         |
| 6.1.1    | Entwicklung einer Extraktionsmethode . . . . .              | 73         |
| 6.1.2    | Software zur Bauteilextraktion . . . . .                    | 77         |
| 6.1.3    | Evaluierung und Effizienz . . . . .                         | 78         |
| 6.2      | Wirtschaftlichkeitsrechnung . . . . .                       | 81         |
| 6.2.1    | Pilotanlage . . . . .                                       | 81         |
| 6.2.2    | Umsetzung in großtechnischen Verfahren . . . . .            | 83         |
| <b>7</b> | <b>Ergebnisse und abschließende Betrachtungen</b>           | <b>87</b>  |
| 7.1      | Wirtschaftliches Potential . . . . .                        | 88         |
| 7.2      | Mögliche Optimierungen . . . . .                            | 89         |
|          | <b>Anhang</b>   | <b>91</b>  |
| A.1      | Zusammensetzung des untersuchten Elektroschrotts . . . . .  | 91         |
| A.2      | Auswertung des Verkaufswerts von Tantalfraktionen . . . . . | 92         |
|          | <b>Literatur- und Quellenverzeichnis</b>                    | <b>95</b>  |
|          | <b>Veröffentlichungen des Autors</b>                        | <b>103</b> |
|          | <b>Betreute Arbeiten</b>                                    | <b>105</b> |
|          | <b>Abbildungsverzeichnis</b>                                | <b>107</b> |
|          | <b>Tabellenverzeichnis</b>                                  | <b>109</b> |
|          | <b>Danksagung</b>   | <b>111</b> |
|          | <b>Eidesstattliche Erklärung</b>                            | <b>113</b> |

# 1 Einleitung und Motivation

Die heutige Informationsgesellschaft ist ein Phänomen des 21. Jahrhunderts. Sie basiert auf dem zunehmenden Austausch von Wissen durch digitale Kommunikation. Um daran teilnehmen zu können, machen sich ihre Mitglieder moderne Kommunikationshardware wie Computer oder Smartphones zunutze, deren Verbreitung deshalb immer weiter steigt. Laut Untersuchungen des Statistischen Bundesamts stieg beispielsweise die Anzahl an Haushalten, die mit einem Computer ausgestattet sind, von 62 % im Jahr 2003 auf 86 % im Jahr 2015 [Sta04, S. 4], [Sta16, S. 45]. Weitaus dramatischer zeigt sich die Zunahme an genutzten Mobiltelefonen. Polák und Drápalová sprechen in ihren Untersuchungen zur Anzahl von Mobiltelefonen in der Tschechischen Republik von einer Steigerung von etwa 45000 Geräten im Zeitraum 1990 - 2000 auf 6,5 Millionen Geräte im Zeitraum 2000 - 2010. Für das aktuelle Jahrzehnt gehen sie nochmals von einer Steigerung auf etwa 26,3 Millionen Geräte aus [PD12].

Aus der großen Verbreitung und den relativ kurzen Lebenszyklen elektronischer Geräte<sup>1</sup> folgt auch eine entsprechende Zunahme des Elektroschrotts. Untersuchungen von Balde et al. haben ergeben, dass die weltweit erzeugte Menge an Elektroschrott pro Kopf von 5,0 kg im Jahr 2010 auf 5,9 kg im Jahr 2014 anstieg [Bal+15, S. 24]. Dabei sind in jedem Elektro- und Elektronik-Altgerät (EAG) verschiedene Komponenten verbaut, die ihrerseits aus unterschiedlichen Materialien bestehen. Einige dieser Materialien, wie beispielsweise Hochtechnologie-Metalle (HT-Metalle)<sup>2</sup>, können weltweit nur an wenigen Lagerstätten wirtschaftlich gewonnen werden. Effektives Recycling ist deshalb eine sinnvolle Methode, um in Ländern mit geringen Rohstoffvorkommen Ressourcen zu erhalten und Abhängigkeiten zu reduzieren.

Aktuelle Industrieverfahren zur Aufarbeitung von Elektroschrott konzentrieren sich auf die Rückgewinnung weniger Stoffe, wie z.B. Gold oder Platinmetalle. Üblicherweise wird der Elektroschrott hierfür vorsortiert, zerkleinert und anschließend mit verschiedenen chemischen Verfahren aufgearbeitet [GNS07]. HT-Metalle bleiben dabei in der Regel in Schlacken aus Schmelzprozessen zurück, die bei der Rückgewinnung von Edelmetallen entstehen. Diese Schlacken werden anschließend verkauft

---

<sup>1</sup>Wissenschaftlichen Analysen zufolge liegt die durchschnittliche Lebensdauer von Notebooks zwischen 4 und 6 Jahren, die von Mobiltelefonen zwischen 2 und 3 Jahren. [Pra+16, S. 128, 130 f.]

<sup>2</sup>HT-Metalle sind definiert als Metalle, die zur Herstellung von Hochtechnologie-Anwendungen unabdingbar sind. [Bun12], [Mel14]

und beispielsweise als Baumaterial eingesetzt. Eine Aufarbeitung ist hingegen nicht wirtschaftlich, da hierbei chemische Rückstände in den Schlacken entstehen würden, die eine weitere Nutzung bzw. den Verkauf ausschließen. Die gesamte Problematik spiegelt sich in den weltweiten Recyclingquoten für HT-Metalle wider, die häufig unter 1 % liegen (z.B. für Ga, In, Ge, Ta). [Bin+13], [Gra+11, S. 19]

Die niedrigen Recyclingquoten der HT-Metalle begründen sich durch fehlende alternative Verfahrenstechnologien und mangelnde Wirtschaftlichkeit. Letztere ergibt sich aus der geringen Konzentration einzelner Stoffe in dem stark durchmischten Elektroschrott. Um eine optimale Wertstoffausbeute zu erzielen, schlagen Binne-mans et al. vor, die zu recycelnden HT-Metalle vor der beschriebenen Behandlung zu entfernen [Bin+13]. Im Rahmen dieser Arbeit wurden deshalb Verfahren untersucht und entwickelt, die der Anreicherung der zu recycelnden HT-Metalle in separaten Fraktionen dienen. Die daraus hervorgehenden Fraktionen können dann wirtschaftlich verwertet werden. Zur Separation wurde das Verfahren der selektiven Extraktion von einzelnen Komponenten gewählt. Die Idee dabei ist die automatische Identifikation und anschließende gezielte Extraktion von entsprechenden Komponenten. Gegenüber der nicht selektiven Extraktion, bei der zuerst alle Komponenten entfernt und anschließend sortiert werden, bietet dieses Verfahren den Vorteil, dass die Identifikation der abzutrennenden Komponenten in unbeschädigtem Zustand erfolgt und potentiell weniger Energie benötigt wird. Weiterhin kann die Güte der separierten Fraktion höher eingeschätzt werden, da nur entfernt wird, was auch gewünscht ist. Voraussetzung hierfür ist jedoch, dass die Identifikation und Extraktion nahezu ohne Fehler erfolgen.

Im nächsten Abschnitt werden die Zusammensetzung des Elektroschrotts und Methoden zur Identifikation der Komponenten erläutert. Darauf aufbauend werden im folgenden Abschnitt die Zielsetzung und vergleichbare Ansätze aus der Forschung genannt. Im Anschluss wird der Aufbau der vorliegenden Arbeit kurz erläutert.

## **1.1 Verfahren zur automatisierten Identifikation von Komponenten**

Elektroschrott setzt sich aus sehr vielen verschiedenen Materialien zusammen. Neben einem hohen Blech- und Kunststoffanteil kommen zusätzlich je nach EAG außerdem Motoren-, Trafo- oder Leiterplattenfraktionen vor. Letztere sind in der Regel mit sehr vielen einzelnen Komponenten bzw. Bauteilen versehen, die ihrerseits über unterschiedlichste Eigenschaften und Materialzusammensetzungen verfügen.

Die Materialzusammensetzungen können dabei selbst für Bauteile des gleichen Typs variieren, da diese je nach Einsatzzweck mit verschiedenen Technologien hergestellt werden. Verdeutlicht werden soll diese Problematik an zwei passiven Bauteilen. Das einfachste elektrische Bauteil ist ein Widerstand. Dieser kann in Form von kleinen,

oberflächenmontierbaren (engl. surface-mount technology, SMT) Quadern mittels Dick- oder Dünnschichttechnik gefertigt werden. Entsprechende Bauteile sind nur wenige Millimeter groß. Aufgrund ihrer geringen Größe eignen sie sich für eine platzsparende Montage bei gleichzeitig geringer Leistungsaufnahme.

Bei hoher Leistungsaufnahme kommen andere Bauformen zum Einsatz, die die entstehende Abwärme besser aufnehmen und abgeben können. Derartige Widerstände können beispielsweise in Form sog. Drahtwiderstände gefertigt und mit Durchsteckmontage (engl. through-hole technology, THT) befestigt werden. Die Baugrößen reichen dabei von einem bis zu mehreren Zentimetern. Ähnliches gilt für Kondensatoren, die sowohl als Keramikvielschichtkondensator in SMT oder als großer Elektrolytkondensator in THT verbaut werden können. Die Aufzählungen der Bauteiltechnologien sind nicht abschließend, sondern nur als Beispiele aus einer Vielzahl möglicher Technologien zu sehen.


Bei Betrachtung einer Gerätegruppe (z.B. Computer) nimmt die Variation der vorkommenden Leiterplattenkomponenten ab und es kommen gehäuft typische Komponenten zum Einsatz, da in jedem Gerät der gleichen Gerätegruppe gleichartige Funktionen bereitgestellt werden müssen (z.B. Energieversorgung oder Steuerung eines Displays). Beispielhaft sind dazu in Abbildung 1.1 mehrere Leiterplatten (engl. printed circuit board, PCB) abgebildet. Häufig vorkommende Komponenten auf Computerleiterplatten sind nachfolgend aufgelistet:

- integrierte Schaltungen (engl. integrated circuit, IC)
  - Linearregler
  - Mikroprozessoren und -controller
  - analoge und digitale Komponenten
- Kühler
- Batterien
- Anschlüsse für Peripherie
- interne Anschlüsse
- Kabel
- Metallstrukturen
- passive Bauelemente
  - Widerstände
  - Kondensatoren
  - Spulen
- aktive Bauelemente
  - Dioden
  - Transistoren
- Schwingquarze

Einige der aufgezählten Komponenten enthalten je nach Aufbau HT-Metalle. So kann in Prozessoren Germanium, das höhere Taktraten erlaubt, enthalten sein. Auch in Kondensatoren können HT-Metalle vorkommen. Tantalkondensatoren bestehen durchschnittlich aus etwa 36,7% Tantal<sup>3</sup>, um eine verhältnismäßig hohe Kapazität bei geringer Baugröße zu erreichen.

---

<sup>3</sup>Dieser Wert ist in der Umbrella-Spezifikation des Zentralverbands Elektrotechnik- und Elektronikindustrie e.V. genannt. Da diese Quelle dem Autor nicht zugänglich ist, wird stattdessen auf eine Sekundärquelle verwiesen. [Mar+16, S. 98]



**Abbildung 1.1:** Vergleichende Darstellung von jeweils zwei Leiterplatten aus Desktop-Rechnern (oben), PC-Bildschirmen (mittig) und Netzteilen (unten). Die Bestückung zeigt Unterschiede hinsichtlich der verbauten Komponenten. Innerhalb der gleichen Gruppe ist die Variation an Bauteilen hingegen gering.

Mehrere Verfahren können in Betracht gezogen werden, um die Komponenten, welche eine gewisse Konzentration an HT-Metallen aufweisen, auf Leiterplatten zu erkennen. So stehen verschiedene Röntgenmethoden wie die Mikroröntgenfluoreszenzanalyse oder das Dual-Energy-Verfahren zur direkten Messung der Materialzusammensetzung zur Verfügung.

Die Anforderungen an den Einsatz eines solchen Verfahrens sind jedoch hoch. Besonders problematisch ist der Umstand, dass die zu untersuchenden Bauteile in Kunstharze eingegossen sind, um sie vor der Umgebung zu schützen. Die verwendete Technologie muss also Messungen durch mehrere Millimeter Kunststoff hinweg ermöglichen. Zudem ist bei einer Bauteilgröße von wenigen Millimetern eine entsprechende Auflösung nötig. Außerdem muss das System einerseits günstig in Anschaffung und Unterhalt sein und andererseits einen hohen Durchsatz bieten, um im Recyclingbereich rentabel betrieben werden zu können.

Neben der direkten Messung der Materialzusammensetzung ist die indirekte Bestimmung der gesuchten Bauteile über ihre äußere Form mittels Bildverarbeitung möglich. Zur Anwendung dieser Methode ist die optische Unterscheidbarkeit der verschiedenen Komponenten untereinander Grundvoraussetzung. Darüber hinaus muss die Materialzusammensetzung in hohem Maße mit der äußeren Form korrelieren, was in der Praxis für viele Bauteile, wie z.B. den Tantalkondensator in SMT, gegeben ist.

## 1.2 Zielstellung und vergleichbare Ansätze

Das Ziel dieser Arbeit bestand im Aufbau eines Systems zur automatischen Identifikation von Komponenten, die durch ihre Zusammensetzung für ein separates Recycling von Interesse sein könnten. Die automatische Identifikation sollte dabei mit modernen Methoden der Bildverarbeitung durchgeführt werden, um eine hohe Detektionsrate der Komponenten zu erreichen. Die dazu nötigen Daten sollten hierfür mit unterschiedlichen Sensoren aufgenommen und anschließend fusioniert werden. Abschließend sollte auch die selektive Extraktion untersucht werden. Im Zentrum dieser Untersuchungen stand die Frage der Umsetzbarkeit und der Wirtschaftlichkeit. Hinsichtlich der untersuchten Komponenten wurde der Schwerpunkt auf Tantalkondensatoren gelegt, die aufgrund der Tantalpreise auch im Fokus der Recyclingindustrie stehen.

Das in dieser Arbeit vorgestellte Konzept basiert auch auf vorangegangenen Arbeiten. Die grundlegende Idee, Komponenten zum Recycling mittels Bildverarbeitung zu identifizieren, wurde bereits Mitte der 90er Jahre untersucht [vR96]. Auch aktuelle Arbeiten verfolgen ähnliche Ansätze. Breier et al. stellen beispielsweise verschiedene Techniken vor, mit denen sie Leiterplattenkomponenten identifizieren. Als Messensoren verwenden sie eine Kamera und einen Linienscanner, die in einem Messaufbau

zum Einsatz kommen, der das hochgenaue Vermessen einzelner Leiterplatten ermöglicht [Bre+16], [Bre+15], [LEB13], [HLB13].

Ein weiteres System, das auf der Bildverarbeitung von 2D-Aufnahmen basiert, wird von Pramerdorfer et al. vorgestellt. Auf Basis des Systems ist eine Datenbank aus hochauflösenden 2D-Bildern entstanden, die mit Markierungen von 10000 integrieren Schaltungen versehen sind [PK15]. Eine Kombination mit 3D-Daten ist gemäß der letzten dem Autor bekannten Veröffentlichung zu diesem Thema zwar geplant, aber noch nicht durchgeführt bzw. veröffentlicht (Stand: Juli 2017) [Kle+15]. In der gleichen Arbeitsgruppe wurde außerdem eine multispektrale Vermessung von Leiterplatten im visuellen Bereich zur Kontrasterhöhung durchgeführt [KK15a].

Hinsichtlich der Tantalextraktion veröffentlichten Schockert et al. 2014 einen Artikel, der die erfolgreiche Vermessung von Tantalkondensatoren mit 3D-Daten im Rahmen einer ersten Studie beschreibt. Hierfür wurden die Daten durch ein Industriesystem aufgenommen und manuell überprüft [SBK14].

Ein umfassender Ansatz, der die Detektion und Extraktion von beliebigen Komponenten auf bzw. aus Leiterplatten miteinbezieht, wird von Knoth et al. bzw. Kopacek et al. beschrieben. Zu bearbeitende Leiterplatten werden dazu manuell in einen Rahmen eingesetzt, der der Fixierung im System dient. Anschließend wird eine nicht näher beschriebene Detektion durchgeführt, welche die zu extrahierenden Komponenten auch anhand von Texterkennung (engl. optical character recognition, OCR) identifiziert. Zur anschließenden Extraktion werden entweder gezielt einzelne Komponenten mit einem Laser erwärmt oder die ganze Leiterplatte mittels Infrarotstrahlung erhitzt, um die Lötverbindungen zu lösen. Ein automatisierter Greifer entfernt im Anschluss die Komponenten. Weitere Systeme und Analysen zur Extraktion sind in Kapitel 6 beschrieben. [Kno+01], [Kop16], [KK15b], [Kop07]

Gegenüber den erwähnten Ansätzen zeichnet sich das hier beschriebene System durch eine innovative Bildverarbeitung aus, die neuartige Verfahren zur Merkmalsberechnung und Klassifikation miteinbezieht. Diese Verfahren sind zum Teil erst seit 2012 bekannt, weshalb eine entsprechende Untersuchung der Verfahren in dem Umfeld der automatischen Identifikation von Leiterplattenkomponenten einen echten Neuwert darstellt. Zudem wurde im Rahmen dieser Arbeit ein Merkmalsvektor entwickelt, mit dem sich bei der Klassifikation von Tantalkondensatoren eine hohe Genauigkeit von über 90 % erreichen lässt. Zur Berechnung dieser Merkmale wurde außerdem eine eigens für Leiterplatten optimierte Segmentierung entwickelt, die die zuverlässige Identifikation von Komponenten erst ermöglicht. Darüber hinaus ist die konsequente Ausrichtung auf den industriellen Sektor ein wesentliches Merkmal dieser Arbeit. Im Unterschied zu den Ansätzen von Breier et al., Pramerdorfer et al. und Schockert et al. werden in dieser Arbeit hochauflösende Industriesensoren für 2D- und 3D-Messungen zur Detektion mit einem Förderband kombiniert, um einen entsprechenden Durchsatz an Leiterplatten sicherzustellen. Dazu werden die Leiterplatten im Gegensatz zu dem Ansatz von Knoth et al. nicht manuell in einen Rahmen gespannt, sondern stattdessen lose auf einem Förderband durch die Anlage

geführt. Darüber hinaus werden in dieser Arbeit und den dazu vorangegangenen Veröffentlichungen konkrete Quoten zur Detektion und Extraktion für verschiedene Bauteilklassen erarbeitet. Die Untersuchungen zur Extraktion umfassen dabei das Testen der Extraktion an mehr als 350 einzelnen Komponenten. Die Detektion wurde mit einer Datenbank mit mehr als 10000 einzelnen Komponenten in über 250 Tests untersucht. Die so bestimmten Quoten wurden für die Abschätzung der Wirtschaftlichkeit herangezogen, wodurch sich die Aussagekraft gegenüber der von Kopacek beschriebenen Wertschöpfung deutlich erhöht, insbesondere vor dem Hintergrund der nicht veröffentlichten Bildverarbeitungsalgorithmik.

### **1.3 Aufbau der Arbeit**

Die vorliegende Arbeit ist in weitere 6 Kapitel gegliedert. Das folgende zweite Kapitel beschäftigt sich mit den Grundlagen, die dem Verständnis der aufgebauten Bildverarbeitungsanlage dienen. Kapitel 3 beschreibt den Aufbau einer eigenen Datenbank, welche die Basis der durchgeführten Analysen und Berechnungen bildet. Anschließend beschreibt Kapitel 4 die Hardware, die für die automatische Detektion der Leiterplattenkomponenten zum Einsatz kommt. Die dazugehörige entwickelte Software ist in Kapitel 5 im Detail beschrieben. Kapitel 6 beschäftigt sich im Anschluss mit dem implementierten Extraktionssystem. Kapitel 7 enthält darüber hinaus abschließende Bewertungen und Vorschläge für weitere Untersuchungen.




## 2 Theoretische Grundlagen

Im nachfolgenden Kapitel sind die theoretischen Grundlagen beschrieben, die dem Verständnis des aufgebauten Systems dienen. Zuerst wird dazu der generelle Aufbau eines Systems zur Bildverarbeitung erläutert. Darauf aufbauend wird anschließend die Funktionsweise der eingesetzten Messverfahren und der zugehörigen Datenverarbeitung im Detail erklärt.

### 2.1 Aufbau eines Bildverarbeitungssystems

Ein typisches Bildverarbeitungssystem zur Detektion („Hier ist ein Bauteil“) und Klassifikation („Dieses Bauteil ist ein Chip“) von Daten ist in mehrere Teilbereiche gegliedert, die konsekutiv miteinander verbunden sind. Ganz am Anfang steht ein Sensorsystem, dessen Daten einen mehrdimensionalen Charakter haben (siehe Abschnitt 2.2). Diese Daten werden im nächsten Schritt mit verschiedenen Algorithmen bearbeitet, etwa um die Daten zu kalibrieren oder Verzeichnungen zu korrigieren. Dieser Teilbereich wird auch Vorverarbeitung genannt (Abschnitt 2.3). Im nächsten Schritt findet die Segmentierung der Daten statt, d.h. die Messdaten werden in verschiedene zusammengehörige Bereiche eingeteilt. Jedes Segment wird mit der Zielsetzung erstellt, möglichst alle Messdaten für exakt eine vollständige Komponente zu umfassen. Im Anschluss werden auf Basis dieser Segmente Merkmale berechnet. Dabei kann es sich z.B. um eine durchschnittliche Höhe oder Farbe handeln (vgl. Abschnitt 2.4). Diese Merkmale werden dann im finalen Schritt an einen Klassifikator (Abschnitt 2.5) weitergereicht, der die Merkmale beurteilt („Bei einer Höhe von 5 mm und dem schwarz-grauen Farbton kann es sich nur um einen Chip handeln“). Je nach verwendetem Klassifikator kann der Schritt der Merkmalsberechnung, der Segmentierung und ggf. auch der Bildvorverarbeitung entfallen, wenn der eingesetzte Klassifikator direkt auf den Bilddaten arbeiten kann. Der komplette Aufbau ist in Abbildung 2.1 dargestellt.



**Abbildung 2.1:** Darstellung des Aufbaus eines möglichen Bildverarbeitungssystems. Die Ausgaben der einzelnen Blöcke sind für ein L-förmiges Objekt dargestellt.

## 2.2 Sensoren zur Vermessung von Leiterplattenkomponenten

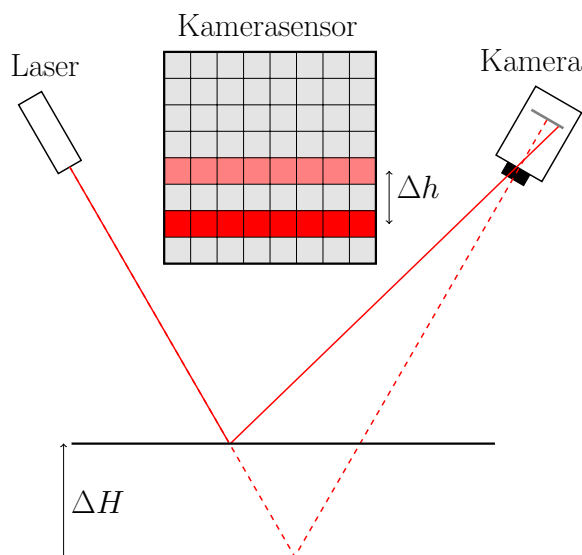
Die Anforderungen an Sensoren zur Datengewinnung eines Bildverarbeitungssystems sind vielfältig. Die Sensoren müssen die benötigte Auflösung bereitstellen, echtzeitfähig sein, in der späteren Einsatzumgebung funktionieren und nicht zuletzt preiswert sein.

Im Rahmen dieser Arbeit wurden verschiedene Messverfahren und die dazugehörigen Sensorsysteme untersucht, um eine sinnvolle Entscheidung für die Anschaffung und den Einsatz in der Pilotanlage treffen zu können. Untersucht wurden sowohl bildgebende Verfahren als auch Methoden aus der Röntgentechnik und Spektroskopie.

### 2.2.1 Bildgebende Verfahren

Der offensichtlichste Weg, Leiterplattenbauteile zu vermessen, besteht im Einsatz und der Auswertung von optischen Verfahren. Diese bieten eine hohe Geschwindigkeit und eine gute Auflösung bis in den 100- $\mu\text{m}$ -Bereich zu einem verhältnismäßig geringen Preis. Eine Standard-Industriekamera ist zum Zeitpunkt dieser Arbeit bereits für weniger als 1000 € erhältlich.

Zur zusätzlichen Erfassung von 3D-Informationen können mehrere Kameras zu einem Stereo- oder Multi-View-Kamerasystem zusammengeschaltet werden. Die Höhendaten eines Objekts werden in diesem Fall aus den Bildern errechnet. Dazu müssen die Kameras in einem definierten räumlichen Versatz und Winkel zueinander angebracht sein. Anschließend werden aufgenommene Objekte, die durch zwei oder mehrere Kameras aufgenommen wurden, einander zugeordnet und die Positionen trianguliert (siehe [HZ04, S. 10 ff.]). Der Nachteil des Verfahrens liegt in der hohen Rechenlast, die das permanente Zuordnen mit sich bringt.



**Abbildung 2.2:** Darstellung des Funktionsprinzips eines Laserscanners

Eine Alternative zur Erfassung von 3D-Informationen bieten sogenannte Laserscanner. Die Höherfassung dieser Geräte basiert auf dem Prinzip der Triangulation einer projizierten Laserlinie. Die Linie wird dabei in einem definierten Winkel zu einer Kamera auf das zu vermessende Objekt abgestrahlt. Je nach Objektabstand wird der Laserstrahl in dem Kamerasensor an unterschiedlichen Stellen abgebildet. Die Positionierung von Laser und Kamera zueinander ist dabei fest vorgegeben, wodurch sich Höhenänderungen bzw. der Abstand zum Sensor über die Position der Linie im Kamerabild berechnen lassen. Das System ist in Abb. 2.2 dargestellt. Zur Vereinfachung wird die Messung zweier Punkte statt zweier Linien dargestellt. Der Aufbau des dargestellten Kamerasensors weist jedoch auf den Liniencharakter des Systems hin. Eine Erweiterung des Prinzips basiert auf dem Einsatz eines Projektors in Kombination mit einer Kamera. Dazu werden mehrere Muster auf die Oberfläche des zu vermessenden Objekts projiziert, mit denen eine örtliche Kodierung der abgedeckten Flächenbereiche ermöglicht wird. Auf Basis der bekannten Muster und dem festen Versatz zwischen Projektor und Kamera kann über die Kodierung der einzelnen Pixel jedem Pixel eine Entfernung zum Sensor zugeordnet werden. Während der Messung muss das untersuchte Objekt jedoch still verharren. [BPF12, S. 303 ff., S. 313 ff.]


Eine weitere Technologie basiert auf der Laufzeitmessung (engl. time of flight, TOF) von Licht. Dazu kommen bei TOF-Kameras Lichtpulse einer bestimmten Wellenlänge zum Einsatz. Diese werden zu einer definierten Zeit auf das Objekt gestrahlt. Reflektiertes Licht wird anschließend von der Kamera aufgenommen. Die Laufzeit des Lichtpulses wird dabei für jedes Pixel einzeln gemessen, wodurch sich über die Lichtgeschwindigkeit für jedes Pixel eine Entfernung ergibt. Auftretende Verzögerungen, die durch die eingesetzten elektronischen Bauelemente bedingt sind, werden zuvor durch Kalibration aufgedeckt und abgezogen. [BPF12, S. 370 f.]

| System  | Auflösung   | FPS    | 2D | 3D | Fb. | Aw. | Preis    |
|---|-------------|--------|----|----|-----|-----|----------|
| Zeilenkamera<br>Teledyne DALSA Piranha XL     | 16352 x 12  | 125000 | +  | -  | +   | +   | 8000 €   |
| Flächenkamera<br>AVT Prosilica GT6600C Cl. 2  | 6576 x 4384 | 4      | +  | -  | +   | +   | 10000 €  |
| Laserscanner<br>LMI Gocator 2420-3R           | 1940 x 1    | 5000   | -  | +  | +   | +   | 10000 €  |
| 3D-Projektion<br>Steinbichler COMET L3D 2     | 2448 x 2050 | 1      | -  | +  | -   | +   | 60000 €  |
| TOF-Kamera<br>PMD CamBoard pico maxx          | 352 x 287   | 60     | -  | +  | +   | +   | 650 €    |
| Multiview-System<br>≥ 2 AVT Prosilica GT2050C | 2048 x 2048 | ca. 30 | +  | +  | +   | -   | > 5000 € |

**Tabelle 2.1:** Vergleich ausgewählter bildgebender Verfahren jeweils anhand eines beliebigen realen Systems. Die Auflösung ist in Pixeln, die maximal mögliche Frequenz in Bildern pro Sekunde (engl. frames per second, FPS) angegeben. „Fb.“ steht für die eingeschätzte Förderbandtauglichkeit und „Aw.“ für den eingeschätzten Aufwand der Inbetriebnahme. Die Preise wurden bei verschiedenen Distributoren für Bildverarbeitungssysteme angefragt (Stand: Juli 2017).

Im Rahmen der Arbeit wurden alle beschriebenen Verfahren bis auf das Multi-View-Kamerasystem einem Praxistest unterzogen, bei dem verschiedene Leiterplatten vermessen wurden. Dabei traten bei der getesteten TOF-Kamera Schwächen in Bezug auf die Genauigkeit der gemessenen Höhe zutage. Konkret ergaben Untersuchungen Messfehler von über 1 cm, womit dieses Messverfahren für die Identifikation von sehr flachen SMT-Komponenten nicht geeignet ist. Weiterhin dauerte eine Messung mit dem Streifenlichtverfahren mehrere Sekunden, wodurch es sich nicht zum Einsatz über Förderbändern eignet. Die Vor- und Nachteile der beschriebenen Verfahren sind in Tabelle 2.1 für ausgewählte Systeme aufgeführt und mit „+“ bzw. „-“ gekennzeichnet. Auf Basis dieser Erkenntnisse wurde eine Flächenkamera in Kombination mit einem Laserscanner für einen maximalen Informationsgewinn zum Einsatz in der Pilotanlage ausgewählt.

Zur Bildaufnahme werden in den meisten Kameras CCD- (engl. charge-coupled device) oder CMOS-Sensoren (engl. complementary metal oxide semiconductor) verwendet. CCD-Sensoren bestehen aus einem zweidimensionalen Aufbau aus analogen Schieberegistern und lichtempfindlichen Flächen. Die nötige Elektronik zur Steuerung muss extern verbaut werden. Bei CMOS-Sensoren ist sie hingegen auf dem Bildsensor integriert. Dadurch können im Gegensatz zu CCD-Sensoren frei wählbare Bildausschnitte mit erhöhter Frequenz ausgelesen werden, wovon in dieser Arbeit auch Gebrauch gemacht wurde. Zudem sind die Herstellungskosten und der Energiebedarf bei sonst sehr ähnlichen technischen Daten niedriger. Aufgrund der genannten Vorteile nimmt die Verbreitung von CMOS-Sensoren immer weiter zu. [BPF12, S. 255-259]



**Abbildung 2.3:** Darstellung des Moiré-Effekts an einem elektronischen Bauteil. Deutlich erkennbar sind die Verfärbungen an den metallischen Kontakten.

Um Farbe erkennen zu können, sind die einzelnen Pixel auf der Kamera mit einem speziellen Farbfilter versehen, das nur für bestimmte Wellenlängenbereiche durchlässig ist. Die Anordnung und Empfindlichkeit der einzelnen Farbpixel wird häufig durch das sogenannte Bayer-Pattern festgelegt. Das Bayer-Pattern besteht aus Pixeln, die mit Filtern für den roten, grünen und blauen Wellenlängenbereich versehen sind. Einzelne Bildzeilen im Bayer-Pattern setzen sich entweder aus grün-blauen oder rot-grünen Pixelpaaren zusammen, die jeweils über die ganze Zeile wiederholt werden. Zur Berechnung der vollständigen Farbbilder (engl. Demosaicing) kommt ein Interpolationsverfahren zum Einsatz, das fehlende Werte über die unmittelbaren Nachbar-Pixel mit der entsprechenden Farbe linear interpoliert [BPF12, S. 261].

Gitterförmige Strukturen, deren projizierter Gitterabstand auf der lichtempfindlichen Fläche im Bereich der Pixelgröße liegt, können dabei nicht korrekt interpoliert werden. Stattdessen treten sogenannte Moiré-Muster auf. Der Effekt wird auch Moiré-Effekt genannt und ist in der zu geringen (örtlichen) Abtastrate der Strukturen begründet. Im aktuellen Anwendungsfall können solche Muster beispielsweise an Bauteilanschlüssen auftreten (siehe Abb. 2.3). Diese Effekte sind beim Einsatz einer Farbkamera letztlich nur durch die Verwendung einer höheren Auflösung zu umgehen, falls die Verkleinerung des Sichtfelds der Kamera nicht gewünscht ist. Andernfalls kann die Auflösung auch erhöht werden, indem der Abstand zwischen Objekt und Kamera variiert oder ein anderes Objektiv verwendet wird. [BPF12, S. 330 ff.]

Neben dem Moiré-Effekt können darüber hinaus noch durch das Objektiv bedingte Abbildungsfehler auftreten. Diese können jedoch durch eine entsprechende Korrektur weitestgehend behoben werden. Das dazugehörige Verfahren ist in Abschnitt 2.3.1 erläutert.

## 2.2.2 Verfahren auf Basis multispektraler Aufnahmen

Multispektrale Aufnahmen bezeichnen Bilddaten, bei denen für jedes einzelne Pixel ein Spektrum von Messwerten existiert. Im Hinblick auf eine Farbkamera kann aufgrund der Aufteilung in die drei Kanäle Rot, Grün und Blau theoretisch ebenfalls von einem multispektralen Messgerät gesprochen werden. Dazu muss jedoch die unterschiedliche Auflösung der einzelnen Kanäle und die Berechnung durch Interpolation beachtet werden. In der Praxis liegt die Anzahl der verwendeten Kanäle zwischen 10 und 100. Diese sind je nach Anwendungszweck der Analyse auf verschiedene Spektren verteilt.

Bei der Auslegung eines multispektralen Systems gibt es grundsätzlich zwei Optionen. Eine Möglichkeit besteht in der Bestrahlung mit einer Lichtquelle, deren Wellenlängenverteilung den ganzen angestrebten Bereich mit einer ausreichenden Intensität abdeckt. Für die Messung wird dann eine Multispektralkamera mit entsprechenden Kanälen verwendet. Die Alternative dazu besteht aus mehreren Messungen mit einem Sensor, der über den kompletten Messbereich eine ausreichende Empfindlichkeit besitzt. Für die einzelnen Messungen wird dann der Wellenlängenbereich des Lichts eingeschränkt, das auf den Sensor trifft. Das ist entweder durch viele schmalbandige Lichtquellen möglich, die das Objekt nacheinander ausleuchten, oder durch den Einsatz von Filtern, die nacheinander vor der Kamera positioniert werden. Der Einsatz einer Multispektralkamera ist zeitlich gesehen wesentlich effektiver, da Systeme dieser Art nur eine Aufnahme machen müssen, wohingegen der zweite Ansatz für jeden Kanal eine separate Aufnahme erfordert.

Nach der Aufnahme der Daten wird typischerweise eine Hauptkomponentenanalyse (engl. principal component analysis, PCA) durchgeführt, um eine Datenreduktion und eine bessere Trennbarkeit zu erzielen. Das PCA-Verfahren ist in Abschnitt 2.4 genauer beschrieben. Anschließend wird die Klassifikation mit einem geeigneten Klassifikator durchgeführt. Die zugehörigen Verfahren sind in Abschnitt 2.5 erläutert.

## 2.3 Algorithmen in der Vorverarbeitung und Segmentierung


Häufig verbessert sich das Ergebnis eines Bildverarbeitungssystems, wenn die Messdaten aus den Sensoren durch verschiedene Algorithmen optimiert werden, bevor sie anschließend weiter verarbeitet werden. Deshalb sind in diesem Abschnitt entsprechende Verfahren erläutert, die sich mit der Kalibration von Bilddaten, der Optimierung und Segmentierung von Binärbildern sowie der Extraktion von Modellparametern durch Stichproben beschäftigen und in dieser Arbeit Anwendung finden.

### 2.3.1 Kalibration von Bilddaten

Die Korrektur der Verzerrung von Kamerabildern ist eine typische Problemstellung, die in der Vorverarbeitung behandelt wird. In der Praxis tritt häufig eine tonnen- oder kissenförmige Verzeichnung auf, die durch intrinsische Kameraparameter definiert ist. Jeweils ein Beispiel dazu ist in Abbildung 2.4 dargestellt. Zur Veranschaulichung wurde die Verzeichnung mit Bildbearbeitung erzeugt. Die für die Arbeit verwendeten Kamerasysteme besitzen eine wesentlich geringere Verzeichnung als in dem gezeigten Beispiel. Die Parameter ergeben sich aus dem Zusammenspiel von Kamera und Objektiv und müssen meist eigenständig bestimmt werden. Zur Bestimmung werden (verzerrte) Bilder von planen Schachbrettmustern mit definierter Länge aufgenommen. Im nächsten Schritt werden alle Eckpunkte der schwarzen Felder des Musters im Bild extrahiert. Durch das Schachbrettmuster kann dieser Schritt teil-automatisiert erfolgen. Anschließend werden ausgehend von einem Zufallswert die intrinsischen Parameter mittels Gradientenabstiegsverfahren ermittelt. Die dabei bestimmten Parameter definieren den Bezug der verzerrten 2D-Koordinaten zum 3D-Raum. Der Fehlerwert der Parameter ergibt sich deshalb über die Rücktransformation der berechneten 3D-Koordinaten in die verzerrten 2D-Farbbilder und deren Abweichung zu den tatsächlichen 2D-Koordinaten. Die mit dem Verfahren gewonnenen Parameter können anschließend zur Entzerrung verwendet werden. Die mathematischen Zusammenhänge des in dieser Arbeit eingesetzten Verfahrens beschreibt Zhang in einer Veröffentlichung [Zha00].

### 2.3.2 Morphologische Operationen zur Binärdatenoptimierung

Binärbilder entstehen häufig durch Vergleiche mit einem Schwellwert. Das kann z.B. ein Helligkeitswert für 2D-Bilder oder ein Höhenwert für 3D-Bilder sein, der die Daten in logisch 0 und 1 unterteilt, je nachdem wie sie zu dem Schwellwert




**Abbildung 2.4:** Darstellung einer kissen- (mittig) und tonnenförmigen Verzerrung (rechts). Der originale Bildausschnitt ist links zu sehen.

liegen. Das hierbei entstehende Rauschen lässt sich mit Filtern für die Binärdaten reduzieren. Besonders häufig kommen Filter zum Einsatz, die als morphologische Operatoren bezeichnet werden.

Alle Filter sind durch eine Filtermatrix definiert, mit der das Bild gefaltet wird. Zur Faltung wird die Filtermatrix mittig über jedes Pixel des Eingangsbilds „gelegt“ und für jede Position elementweise multipliziert. Die Einzelresultate werden anschließend aufaddiert und mit einem Schwellwert verglichen. Das Ergebnis des Vergleichs resultiert dann in einem neuen Pixel im Ausgangsbild mit dem Wert logisch 0 oder 1. Aufgrund des Vorgehens können Pixel am Rand nicht gefiltert werden, weshalb die Größe des Ausgangsbildes unter der des Eingangsbildes liegt. Zur Vermeidung dieses Effektes kann das Eingangsbild entsprechend vergrößert werden. [Sze11, S. 112 f.]

Häufig eingesetzte Filter dienen der Erosion oder Dilatation sowie dem Öffnen und Schließen von Lücken oder Löchern in Binärbildern. Weiterhin werden sie zur Rauschunterdrückung eingesetzt. Die Wirkungsweise jedes morphologischen Operators ist durch die Größe und Zusammensetzung seiner Filtermatrix und den entsprechenden Vergleichswert definiert. Zur Erosion wird beispielsweise der zum Vergleich genutzte Schwellwert so gelegt, dass alle Pixel im Bereich des Operators logisch 1 sein müssen, um eine 1 im Ausgangsbild zu erzeugen. Im Gegensatz dazu liefert die Dilatation 1, falls mindestens eines der an der Faltung beteiligten Binärpixel logisch 1 ist. Der Vorgang des Öffnens entspricht einer Erosion mit anschließender Dilatation, das Schließen dem Gegenteil. Ein Beispielbild für eine Erosion und Dilatation ist in Abb. 2.5 zu sehen. Der angewendete Erosions- und Dilatationsfilter entspricht einem Kreis mit einem Durchmesser von 3 Pixeln. Binärpixel mit dem Wert logisch 1 sind in schwarz dargestellt. [Sze11, S. 113]

Die Parameter der beschriebenen Verfahren begrenzen sich auf die Größe und Form des eingesetzten Elements und bieten Ansatz für Optimierungen. Beide Verfahren, sequentiell angewandt, ermöglichen eine effektive Rauschunterdrückung und die Reduktion von feinen Details. [Dav05, S. 234]



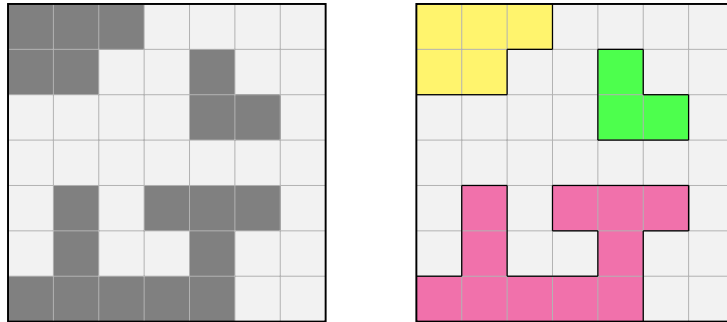
**Abbildung 2.5:** Erosion und Dilatation für ein beliebiges Eingangsbild (links). Erodierte Pixel sind rot, dilatierte Pixel blau dargestellt.

### 2.3.3 Detektion von zusammenhängenden Objekten in Binärdaten


Ein häufiger Anwendungsfall von Binärbildern ist das Finden von zusammenhängenden Objekten (engl. binary large objects, BLOBs). Diese sind durch eine größere Anzahl an zusammenhängenden Pixeln mit dem logischen Wert 1 gekennzeichnet. Pixel mit dem logischen Wert 0 werden dem Hintergrund zugeordnet. In der vorliegenden Arbeit wird die BLOB-Detektion zur Gruppierung zusammenhängender Messwerte verwendet.

Zur Erkennung der BLOBs wird ein spezielles Verfahren angewandt. Dazu wird ein Strukturelement eingesetzt, welches das Binärbild von links oben nach rechts unten durchläuft und für jedes Pixel mit dem logischen Wert 1 überprüft, ob es einen neuen BLOB bildet oder Teil eines bereits erkannten BLOBs ist. Jedem Pixel wird dabei eine Identifikationsnummer zugewiesen, die für die Nummer des zugehörigen BLOBs steht. Der Hintergrund wird mit der Objektnummer 0 gekennzeichnet. Zusammenhängende Pixel tragen so die gleiche Nummer. Falls ein Pixel kein vorhergehendes Pixel berührt, bekommt es eine neue Nummer. Aufgrund des sequentiellen Charakters können eventuell Fälle auftreten, bei denen zusammenhängende Objekte im ersten Durchlauf nicht dieselbe Nummer bekommen, beispielsweise bei einem U-förmigen Objekt. Deshalb wird nach dem ersten Durchlauf das Ergebnis erneut untersucht, wobei das Strukturelement nun alle benachbarten Pixel untersucht. Das Resultat ist eine Matrix, in der für jedes Pixel die zugehörige Objektnummer enthalten ist. Ein Beispiel ist in Abb. 2.6 zu sehen. Binärpixel mit dem Wert logisch 0 bzw. 1 sind hellgrau bzw. dunkelgrau hinterlegt. Die drei resultierenden BLOBs sind zur Veranschaulichung in verschiedenen Farben hervorgehoben. [Sze11, S. 115]

Für den Algorithmus ist dabei die Definition von „zusammenhängend“ wichtig. Meist sind hier Pixel gemeint, die horizontal oder vertikal in unmittelbarer Nachbarschaft zueinander stehen. Alternativ können auch die Pixel mit einbezogen werden, die diagonal miteinander verbunden sind. Eine Gegenüberstellung ist in Abb. 2.7 zu sehen. [Pra01, S. 401 ff.]



**Abbildung 2.6:** Darstellung einer BLOB-Detektion



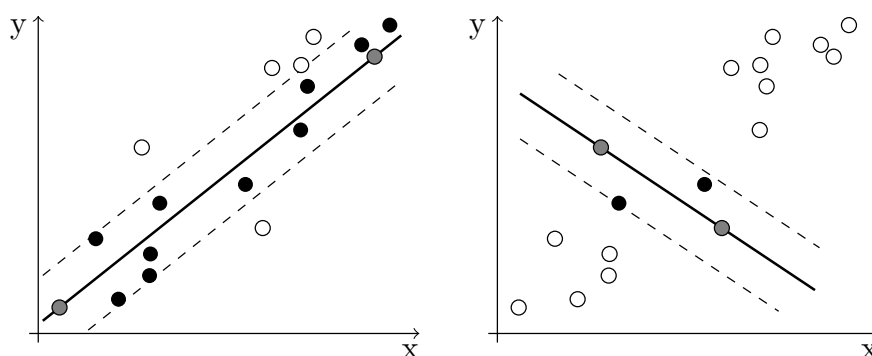
**Abbildung 2.7:** Darstellung von BLOBs für verschiedene Definitionen von „zusammenhängend“. Bei der Definition über die vier direkt anliegenden Pixel ergeben sich fünf unterschiedliche Objekte (b), bei zusätzlicher Prüfung der diagonalen Verbindungen hingegen ein zusammenhängendes Objekt (c). Die Eingangsdaten sind unter (a) dargestellt. Binärpixel mit dem Wert logisch 1 sind in dunkelgrau hervorgehoben. Der Bereich der jeweiligen Definition ist für das mittlere Pixel rot umrahmt.

### 2.3.4 Schätzung von Modellparametern mittels zufälliger Stichprobe

In der Bildverarbeitung sind bei stationären Systemen häufig sich wiederholende Zusammenhänge gegeben, die durch entsprechende Modelle angenähert werden können. Im Rahmen dieser Arbeit zählt dazu beispielsweise die Oberfläche der zu untersuchenden Leiterplatten. Um diese mit einer Ebene anzunähern, können die Parameter iterativ mittels zufälliger Stichprobe geschätzt und überprüft werden. Dieses Verfahren (engl. random sample consensus, RANSAC) lässt sich für beliebige Modelle einsetzen und ist durch die Berücksichtigung von falschen Daten relativ robust gegenüber Messrauschen oder Messfehlern. Das grundlegende Verfahren ist nachfolgend beschrieben.

Aus der Masse der zu untersuchenden Datenpunkte werden zunächst  $k$  Punkte gezogen. Das Ziehen geschieht zufällig, was sich im Namen des Verfahrens niederschlägt. Anhand der gezogenen Punkte wird nun das Modell berechnet, beispielsweise die Steigung und Verschiebung einer Geraden oder die Koeffizienten einer Ebene. Im nächsten Schritt werden alle Datenpunkte auf ihre Abweichung zu diesem Modell hin überprüft. Ein Punkt stützt dabei das Modell, falls seine Abweichung dazu kleiner ist als ein vordefinierter Schwellwert  $T$ . Außerhalb des Schwellwertes liegende Punkte werden als Ausreißer betrachtet. Abbildung 2.8 verdeutlicht den Zusammenhang anhand von zwei Beispielen. Bei den zugrunde liegenden Daten handelt es sich um stark verrauschte Messungen, die durch eine Gerade verbunden werden sollen. Die zufällig ausgewählten Stichproben zur Gewinnung der Modellparameter sind jeweils grau hinterlegt. [Dav05, S. 861 ff.]

Das Verfahren wird  $S$  mal wiederholt. Für jeden Durchlauf wird der sog. Konsensus, die Menge der Modellstützpunkte, abgespeichert. Letztlich werden dann die Modellparameter genutzt, die das Modell mit dem größten Konsensus beschreiben.



**Abbildung 2.8:** Bestimmung einer Geraden mittels RANSAC. Die Messpunkte sind über einen gestrichelten Schwellwert in Stützpunkte ( $\bullet$ ) und Ausreißer ( $\circ$ ) aufgeteilt.

Die Anzahl der nötigen Durchläufe  $S$  kann über die Wahrscheinlichkeiten  $P$  und  $p$  gem. Gl. 2.1 vorbestimmt werden.  $P$  gibt die Wahrscheinlichkeit an, ein korrektes Modell zu finden, während  $p$  den zu erwartenden Anteil an Stützpunkten an den gesamten Messwerten angibt. Der Wert  $k$  entspricht der Anzahl der benötigten Messwerte zur Modellberechnung. [Sze11, S. 281 f.]

$$S = \frac{\log(1 - P)}{\log(1 - p^k)} \quad (2.1)$$


Eine Modifikation des RANSAC-Verfahrens ist der sog. MSAC (engl. M-estimator sample consensus), der zusätzlich die Abweichung des Modells in die Beurteilung miteinbezieht. Die Fehlersumme, die das beste Modell bestimmt, wird nun nicht mit der Anzahl der Ausreißer berechnet. Stattdessen wird eine leicht modifizierte Abweichung  $\tilde{e}$  der Punkte vom Modell herangezogen. Die modifizierte Abweichung  $\tilde{e}$  berechnet sich gem. Gl. 2.2 und setzt sich aus 2 Fällen zusammen, wobei  $e$  der Abweichung zwischen Modell und Messpunkt und  $T$  einem festgelegten Schwellwert zur Unterscheidung von Modellstützpunkten und Ausreißern entspricht. Dadurch wird der Einfluss von guten Punkten im Modell stärker gewichtet und das Verfahren insgesamt robuster. [TZ00]

$$\tilde{e} = \begin{cases} e^2, & \text{falls } e^2 < T^2 \\ T^2, & \text{falls } e^2 \geq T^2 \end{cases} \quad (2.2)$$

## 2.4 Verfahren zur Merkmalerstellung

Verfahren zur Merkmalerstellung bieten Möglichkeiten zur Gewinnung von gewissen Eigenschaften aus Rohdaten. Die Eigenschaften sollen dabei möglichst spezifisch und charakteristisch ausfallen, um die darauffolgende Datenanalyse zu erleichtern. Im Fall der Klassifizierung sollen die erstellten Eigenschaften sinnvolle Rückschlüsse auf die in den Daten vorkommenden Objektklassen zulassen. Sinnvoll bedeutet in diesem Fall, dass ein Klassifikationsalgorithmus mit den Messdaten eine hohe Erkennungsrate erzielt. Das Erstellen und Auswählen von Merkmalen wird regelmäßig als wichtigster Erfolgsfaktor für Projekte bezeichnet, die sich mit maschinellem Lernen beschäftigen [Dom12].

Nutzbare Eigenschaften sind im Fall dieser Arbeit beispielsweise Bauteilhöhe oder Farbe. Mehrere Eigenschaften oder Merkmale werden zu einem Merkmalsvektor zusammengefasst. Der Zweck der Merkmale liegt vor allem in ihrer Eigenschaft, Kenngrößen zu messen, welche die zu klassifizierenden Objekte deutlich voneinander unterscheidbar machen. Gute Merkmalswerte liegen für verschiedene Klassen im Merkmalsraum weit voneinander entfernt. Für gleiche Klassen liegen sie jedoch




**Abbildung 2.9:** Veranschaulichung der Streuung unterschiedlicher Merkmalswerte ( $\circ$ ) eines „guten“ (links) und „schlechten“ Merkmals (rechts)

eng beieinander und bilden zusammenhängende Gruppen (engl. Cluster) aus. Abbildung 2.9 stellt beispielhafte zweidimensionale Merkmalswerte für zwei unterschiedliche Merkmale dar, die auf den gleichen beliebigen Objekten basieren sollen. Die Objekte gehören einer von drei möglichen Klassen an.

Die Eigenschaften der gemessenen Objekte liegen in einem anderen Raum als die Rohdaten. Dieser Raum wird als Merkmalsraum (engl. feature space) bezeichnet und besitzt typischerweise weniger Dimensionen als der Messraum. Falls der Merkmalsraum sehr viele Dimensionen besitzt, kann die Durchführung einer Merkmalsextraktion sinnvoll sein. Bei der Extraktion kommen Verfahren zum Einsatz, die einen Merkmalsvektor mit vielen korrelierenden Merkmalsdimensionen mit geringer Aussagekraft idealerweise so zusammenfassen, dass ein niederdimensionaler Vektor mit wenigen Einträgen, die eine hohe Aussagekraft besitzen, entsteht. Ein Verfahren, das hier zum Einsatz kommen kann, ist die bereits erwähnte Hauptkomponentenanalyse.

Ein einfaches Beispiel soll den Zusammenhang verdeutlichen: Ein potentieller Merkmalsvektor besteht aus der Konkatenation aller verfügbaren Pixelwerte eines Bauteils, die mit einem Farbbild gemessen werden können. Angenommen ein Bauteil wird im Bild von  $100 \times 100$  Pixeln dargestellt, dann ergibt sich ein Merkmalsvektor der Größe  $100 \times 100 \times 3 = 30000$  Dimensionen. Die zusätzliche Multiplikation mit 3 ergibt sich aus den Farbkanälen Rot, Grün und Blau. Es ist offensichtlich, dass einzelne Einträge innerhalb dieses Vektors nicht sehr aussagekräftig sein können, Kombinationen verschiedener Einträge hingegen schon. Eine Kombination könnte beispielsweise die gleich gewichtete Summe aller Rot-, Grün- und Blau-Werte sein, was der durchschnittlichen Helligkeit entspricht. Diese und andere weniger offensichtliche Zusammenhänge werden als Hauptkomponenten mittels PCA erkannt.

Eine Hauptkomponente ist dabei eine Richtung im Raum der Rohdaten, die eine besonders hohe Varianz der Daten aufzeigt. Sie besteht aus einer Linearkombination der originalen Messdaten. Zur Berechnung der Hauptkomponenten eines beliebigen Datensatzes muss dieser zuerst auf den Ursprung verschoben werden, indem der Erwartungswert subtrahiert wird. Anschließend werden die Kovarianzmatrix des Datensatzes sowie deren Eigenvektoren und Eigenwerte berechnet. Die größten Ei-



**Abbildung 2.10:** Darstellung der Variation von Daten entlang ihrer Hauptkomponenten. Die Zeichnung ist angelehnt an eine Abbildung aus [Rue+17b].

genwerte gehören dabei zu den Eigenvektoren, welche die Variation innerhalb der Daten am stärksten beschreiben. Häufig kann durch die Verwendung von wenigen Eigenvektoren bzw. Hauptkomponenten fast die gesamte Varianz der Daten beschrieben werden, wodurch sich die erwähnte Datenreduktion ergibt. Im konkreten Fall der Transformation eines Messwerts werden die ausgewählten Hauptkomponenten bzw. Linearkombinationen berechnet und das niederdimensionale Resultat in der Klassifikation weiterverarbeitet. Abbildung 2.10 veranschaulicht einen beliebigen zweidimensionalen Datensatz und seine zwei Hauptkomponenten. Die Variation der Daten in Richtung der ersten Hauptkomponente  $pc_1$  ist dabei erkennbar größer als in Richtung von  $pc_2$ . [Sze11, S. 647 ff.]

In vielen Systemen werden häufig erprobte Merkmalsberechnungsverfahren entsprechend der Fragestellung ausgewählt. Auch die zu untersuchenden Objekte müssen miteinbezogen werden. Falls die Objekte starke Farbkanten in 2D-Daten aufweisen, können Histogramme für die Richtungen der vorkommenden Gradienten (engl. histogram of oriented gradients, HOG) als Merkmale verwendet werden. Im HOG-Verfahren wird die auszuwertende Datenmatrix in einzelne Blöcke aufgeteilt und für jeden Block ein Histogramm der darin vorkommenden Gradienten erstellt. Der finale Merkmalsvektor besteht dann aus den einzelnen verketteten Richtungshistogrammen. [DT05]

Ein anderer Algorithmus, der im Rahmen der Klassifikation von Texturen in Bildern zum Einsatz kommt, basiert auf der Untersuchung der Größenverhältnisse benachbarter Pixel und deren Auswertung mittels Histogrammen (engl. local binary patterns, LBP). Auch im sog. LBP-Verfahren werden die Daten zuerst in Blöcke aufgeteilt. Anschließend findet für jedes Pixel innerhalb des Blocks ein Vergleich mit den 8 benachbarten Pixeln statt. Der Vergleich wird in Form eines Binärcodes abgespeichert. Ist der Wert eines Nachbarpixels größer, kommt eine 1 an die entsprechende Stelle, andernfalls eine 0. Alle Binärcodes innerhalb eines Blocks werden zu einem Histogramm zusammengefasst. Die konkatenierten Histogramme aller Blöcke bilden dann den finale Merkmalsvektor. [OPH94]

Falls die Fragestellung nicht die Klassifikation von Objekten ist, sondern die Übereinstimmungen zwischen zwei Bildern gefunden werden sollen, eignen sich unter anderem sog. A-KAZE-Merkmale. A-KAZE steht dabei für beschleunigte KAZE (engl. accelerated KAZE, A-KAZE), KAZE bedeutet auf Japanisch Wind. Im Gegensatz zu HOG- und LBP-Merkmalen sind KAZE-Merkmale so ausgelegt, dass sie möglichst unabhängig gegenüber Drehungen, Größenänderungen und Helligkeitsschwankungen sind. Zur Berechnung werden die zu untersuchenden Bilder durch Filterung in verschiedene sog. Skalenräume überführt. Die Räume unterscheiden sich untereinander durch den enthaltenen Detailgrad. Innerhalb der Skalenräume werden mittels eines normalisierten Hesse-Filters lokale Extremwerte gefunden, deren dominante Orientierung bzw. Richtung anschließend mit der ersten Ableitung bestimmt wird. Ausgehend von der berechneten Richtung wird der benachbarte Bereich um den Extrempunkt, auch in benachbarten Skalenräumen, in quadratische Blöcke aufgeteilt. Der finale Merkmalsvektor für einen Extrempunkt ergibt sich dann aus den konkatenierten Summen über die ersten Ableitungen und deren Beträge aus den in den Blöcken enthaltenen Daten. Insbesondere die Berechnung der Skalenräume ist dabei sehr rechenaufwendig. Diese Berechnung wird durch Approximation im A-KAZE nochmals beschleunigt. [ABD12], [ANB13]

## 2.5 Algorithmen zur Klassifizierung

Bei der Klassifizierung handelt es sich um die Prädiktion der Klassenzugehörigkeit von Daten. Üblicherweise kommt dazu ein trainierter Klassifikationsalgorithmus zum Einsatz, der auf Basis zuvor gelernter Beispiele entscheidet. Dieser Abschnitt beschreibt die Funktionsweise von Algorithmen, die zur Klassifikation eingesetzt werden können. Im folgenden Unterkapitel werden hierfür zuerst zum Verständnis nötige Grundlagen kurz erläutert. Anschließend folgt die Vorstellung ausgewählter Klassifikatoren und Möglichkeiten für deren Bewertung.

### 2.5.1 Grundlagen zur Klassifizierung

Um einen Klassifikationsalgorithmus zur Prädiktion verwenden zu können, muss dieser zuerst trainiert bzw. angeleitet werden. Dabei wird zwischen überwachtem und unüberwachtem Lernen unterschieden. Beim überwachten Lernen ist das zu erzielende Resultat in Form von Klassenzugehörigkeiten für die Trainingsdaten bereits bekannt und die Informationen werden auch zum Training genutzt. Alle nachfolgenden Klassifikatoren fallen unter diese Kategorie. Im Gegensatz hierzu bezeichnet unüberwachtes Lernen Lernverfahren, bei denen der Klassifikator in einer Menge gleichwertiger Daten (unbekannte) Zusammenhänge findet. [Bae14, S. 87]

Um einen Klassifikator mittels überwachtem Lernen zu trainieren, werden typischerweise nachfolgende Schritte durchgeführt:

1. Datenaufnahme
2. Merkmalsextraktion (optional)
3. Einteilung der Daten in Klassen
4. Training des Klassifikators
5. Evaluierung der Klassifikation

Der erste Schritt umfasst das Erzeugen oder die Aufnahme von sog. Trainingsdaten, die den später zu klassifizierenden Daten stark ähneln. Je nach Klassifikator werden mehr oder weniger Daten benötigt, um eine gute Klassifikation zu ermöglichen. Die Datenbanken, die für das Training von sog. convolutional neural networks (CNN) verwendet werden, umfassen beispielsweise  $10^5$  bis  $10^6$  einzelne Trainingsbeispiele. Je umfassender die Daten dabei die Wirklichkeit inklusive aller Sonderfälle abbilden, desto besser lassen sich die Modelle im Anschluss trainieren.

Im nächsten Schritt werden die Merkmale aus den Rohdaten extrahiert. Manche Klassifikatoren können jedoch direkt mit den Rohdaten arbeiten. Beispielsweise können CNNs direkt auf Bilddaten eine entsprechende Klassifizierung durchführen.

Anschließend werden den Daten einzelne Klassen zugewiesen. Dieser Schritt erfolgt normalerweise manuell und ist je nach Art der Daten sehr zeitaufwendig. Im Falle dieser Arbeit wurden beispielsweise Bilddaten visuell auf darin vorkommende Komponenten überprüft und entsprechende Objekte markiert. Der genaue Ablauf ist in Kapitel 3 beschrieben.

Die markierten Daten werden nun zufällig in ein Trainingsset und ein Testset eingeteilt, beispielsweise im Verhältnis 2 zu 1. Testdaten stehen im Training nicht zur Verfügung. Das Trainingsset wird an den Klassifikator zum Training weitergeleitet. Je nach Klassifikator und Parametereinstellung wird das Trainingsset mehrmals konsekutiv evaluiert, bis die Fehlerrate für das Trainingsset eine zuvor gesetzte obere Schranke unterschreitet.

Abschließend wird die Detektionsrate des Klassifikators mit dem Testset überprüft. Dabei kommen neben der reinen Anzahl der korrekten Prädiktionen auch andere Kenngrößen zum Einsatz, die in Abschnitt 2.5.6 erläutert werden. Der trainierte Klassifikator kann anschließend zur Detektion eingesetzt werden.

## 2.5.2 Support Vector Machines

Stützvektormaschinen, im Folgenden nur noch unter der gängigen engl. Bezeichnung support vector machines (SVM) aufgeführt, sind Verfahren zur direkten bzw. expliziten Bestimmung einer Trennebene zwischen zwei unterschiedlichen Klassen. Jede Trennebene teilt dabei den Raum, in dem sich die Datenpunkte oder Merkmale der zwei Klassen befinden, in zwei Teile. Jede Seite wird dabei einer Klasse zugeordnet. Der Raum, in dem die Ebene liegt, wird aufgrund der hohen Dimensionalität der Merkmale auch als Hyperraum bezeichnet. Dementsprechend werden Trennebenen in der Literatur auch als Hyperebenen bezeichnet. Bei dem SVM-Verfahren wird die Trennebene im Wesentlichen durch sogenannte Stützvektoren festgelegt. Stützvektoren sind Trainingsdatenpunkte, die im Hyperraum direkt an der Klassengrenze liegen. Nachfolgend werden zuerst die gesuchte Trennebene und deren Berechnung anhand eines Zwei-Klassen-Problems erläutert. Im Anschluss werden modifizierte SVM-Verfahren für Multi-Klassen-Probleme erörtert. Die dargestellten Methoden und Gleichungen sind verschiedenen Quellen entnommen [Abe05], [CL14], [SS02].

Jede Trennebene im Raum  $\mathbb{R}^n$ , die beliebige Punkte  $\mathbf{x}$  trennt, ist über eine Normale  $\mathbf{w}$  und eine Nullpunktverschiebung  $b$  genau definiert. Zur Berechnung der Klassenzugehörigkeit wird der Abstand des Punkts  $\mathbf{x}_i$  zur festgelegten Ebene mit Gl. 2.3 berechnet. Per Definition gehören Punkte mit einem Abstand größer 1 zu Klasse 1. Dementsprechend werden Punkte mit Abständen kleiner -1 der Klasse 2 zugeordnet (Gl. 2.4). Die zu  $\mathbf{x}_i$  gehörige Klasseninformation ist dabei in  $y_i$  mit 1 (Klasse 1) bzw. -1 (Klasse 2) gespeichert. [Abe05, S. 15 f.]


$$f_{\mathbf{w},b}(\mathbf{x}_i) = \langle \mathbf{w}, \mathbf{x}_i \rangle + b \quad (2.3)$$

$$\langle \mathbf{w}, \mathbf{x}_i \rangle + b \begin{cases} \geq 1, & \text{falls } y_i = 1 \\ \leq -1, & \text{falls } y_i = -1 \end{cases} \quad (2.4)$$


Damit die Mengen an Punkten, die jeweils einer der zwei Klassen zugeordnet werden können, mit einer Trennebene in  $\mathbb{R}^n$  trennbar sind, muss Gl. 2.5 erfüllt sein. Ist das der Fall, werden die Punkte als linear separabel bezeichnet, wodurch sich typischerweise beliebig viele Trennebenen ergeben, die die Einteilung aus Gl. 2.4 erfüllen. Abbildung 2.11 verdeutlicht diesen Zusammenhang.

$$y_i(\langle \mathbf{w}, \mathbf{x}_i \rangle + b) \geq 1, \quad \forall i \in \{1, \dots, m\} \quad (2.5)$$

Per Definition gibt es aus der Menge der möglichen Ebenen eine optimale Ebene. Sie ist so definiert, dass der Abstand zu den Punkten, die ihr am nächsten liegen,



**Abbildung 2.11:** Darstellung mehrerer möglicher Trennebenen für linear separable Datenpunkte zweier Klassen  $\bullet$  und  $\circ$ , angelehnt an [Bae14, S. 59]



**Abbildung 2.12:** Darstellung einer optimalen und suboptimalen (gestrichelt) Trennebene mit den Begrenzungen und Stützvektoren (grau ausgefüllte Datenpunkte), angelehnt an [SS02, S. 12] und [Abe05, S. 17]

maximal wird (siehe Abbildung 2.12). Der Abstand ist dabei durch  $1/\|\mathbf{w}\|$  terminiert. Daraus folgt, dass für „gute“ Ebenen  $\|\mathbf{w}\|$  möglichst klein sein muss. Aus dem Betrag in Gl. 2.4 ergeben sich zwei Begrenzungsebenen  $y_i(\langle \mathbf{w}, \mathbf{x}_i \rangle + b) = 1$  und  $y_i(\langle \mathbf{w}, \mathbf{x}_i \rangle + b) = -1$ . Diese umranden die Trennebene, wie in Abbildung 2.12 dargestellt. Die Begrenzungen sind durch die namensgebenden Stützvektoren festgelegt. Hierbei handelt es sich um die bereits erwähnten Datenpunkte mit dem geringsten Abstand zur Ebene. Im Normalfall liegen die Stützvektoren auf den Begrenzungen. [Abe05, S. 16], [SS02, S. 12], [CL14, S. 130]

Zur Berechnung der optimalen Ebene kann ein Minimierungsproblem aus Gleichung 2.5 und dem maximalen Abstand über  $1/\|\mathbf{w}\|$  definiert werden. Das Quadrat der euklidischen Norm wird dabei genutzt, um das folgende Minimierungsproblem mit Methoden der mathematischen Optimierung zu lösen (Gl. 2.6). [Abe05, S. 17], [SS02, S. 12 f.]

$$\underset{\mathbf{w} \in \mathbb{R}^n, b \in \mathbb{R}}{\text{Minimiere}} \quad Q(\mathbf{w}) = \frac{1}{2} \|\mathbf{w}\|^2 \quad (2.6)$$

unter der Bedingung

$$y_i(\langle \mathbf{w}, \mathbf{x}_i \rangle + b) = 1, \quad \forall i \in \{1, \dots, m\}. \quad (2.7)$$

Zum Lösen wird das Problem zuerst mithilfe der Lagrange-Funktion und sogenannten Lagrange-Multiplikatoren umformuliert (Gl. 2.8). Die Lagrange-Multiplikatoren  $\alpha_i$  sind dabei größer-gleich 0. In der finalen Lösung geben  $\alpha_i$  größer Null dann die Stützvektoren  $\mathbf{x}'_i$  an, welche die Trennebene definieren. [Abe05, S. 19]

$$Q(\mathbf{w}, b, \boldsymbol{\alpha}) = \frac{1}{2} \|\mathbf{w}\|^2 + \sum_{i=1}^m \alpha_i (y_i(\langle \mathbf{w}, \mathbf{x}_i \rangle + b) - 1) \quad (2.8)$$

Anschließend wird die Lagrange-Funktion unter Verwendung von Karush-Kuhn-Tucker-Bedingungen (KKT) gemäß Abe [Abe05, S. 19] zu einem dualen Problem umformuliert, das sich mit entsprechenden Softwarealgorithmen einfach lösen lässt:

$$Q(\boldsymbol{\alpha}) = \sum_{i=1}^m \alpha_i - \sum_{i,j=1}^m \alpha_i \alpha_j y_i y_j \langle \mathbf{x}_i, \mathbf{x}_j \rangle \quad (2.9)$$

Dabei gelten die Bedingungen

$$\sum_{i=1}^m y_i \alpha_i = 0, \quad \alpha_i \geq 0, \quad \forall i \in \{1, \dots, m\}. \quad (2.10)$$

Nur die Messpunkte  $\mathbf{x}_i$ , deren zugehöriges  $\alpha_i$  größer 0 ist, sind für die Lösung von Bedeutung. Die restlichen Punkte spielen keine Rolle. Selbst beim Weglassen der unwichtigen Punkte würde die gleiche Trennebene berechnet werden.

In der Praxis sind die Daten meist nicht linear separabel. Um dennoch eine Klassifizierung mittels SVM zu ermöglichen, werden in die Lagrange-Funktion sogenannte Schlupfvariablen  $e$  eingebaut. Diese erlauben eine Abweichung  $e_i$  vom korrekten Klassifizierungsergebnis  $y_i$ , wodurch sich die Bedingung für das Minimierungsproblem gem. Gl. 2.11 ändert:

$$y_i(\langle \mathbf{w}, \mathbf{x}_i \rangle + b) \geq 1 - e_i \quad (2.11)$$

Die Abweichungen  $e$  sind gem. Gl. 2.12 definiert und sollen möglichst klein sein. [SS02, S. 16], [CL14, S. 132]

$$e_i \geq 0, \forall i \in \{1, \dots, m\} \quad (2.12)$$

Durch die Änderung in der Lagrange-Funktion ändert sich auch die Umformung in das duale Problem über die KKT-Bedingungen. Der genaue Ablauf für diesen Fall wird von Schölkopf und Smola [SS02, S. 16 f.] ausführlich geschildert. Die dadurch berechneten Trennebenen werden aufgrund der geringeren Trennschärfe auch als weiche Trennebenen (engl. soft margin classifier) bezeichnet.

Neben der Einführung von Schlupfvariablen können nicht trennbare Eingangsdaten auch durch die Verwendung von sogenannten Kernel bzw. Kernelfunktionen  $H(\mathbf{x}, \mathbf{x}')$  trennbar gemacht werden, wobei  $\mathbf{x}'$  Stützvektoren sind. Die Kernelfunktionen transformieren dazu die Eingangsdaten in einen höherdimensionalen Raum  $\mathbb{R}^t$ , in dem die Daten dann wieder durch eine entsprechende Ebene trennbar sind (siehe Abbildung 2.13). Es sind viele Kernelfunktionen bekannt, die gute Ergebnisse erzielen. Nachfolgend werden zwei häufig eingesetzte Kernel kurz erläutert:

- Polynomialkernel basieren auf der Kernelfunktion

$$H(\mathbf{x}, \mathbf{x}') = (\langle \mathbf{x}, \mathbf{x}' \rangle + 1)^d. \quad (2.13)$$

Um alle Monome bei der Potenzierung mit dem Exponenten  $d$  zu erhalten, wird dem Skalarprodukt hierfür 1 hinzugefügt. [Abe05, S. 27]


- Gaußsche radiale Basisfunktion-Kernel (RBF) verwenden den quadrierten euklidischen Abstand

$$H(\mathbf{x}, \mathbf{x}') = \exp(-\gamma \|\mathbf{x} - \mathbf{x}'\|^2) \quad (2.14)$$

zur Transformation, wobei  $\gamma$  ein Skalierungsfaktor für den Radius ist. [Abe05, S. 27 f.]

Bis jetzt wurde nur die Lösung von Zwei-Klassen-Problemen beschrieben. Natürlich lassen sich mit dem Verfahren der SVM auch Multi-Klassen-Probleme lösen, indem mehrere Trennebenen verwendet werden. Bei der Verwendung von mehreren Ebenen kommt es jedoch meist zur Bildung von Räumen, die keiner Klasse zugeordnet werden können (siehe Abbildung 2.14).


Die Trennebenen können mit verschiedenen Algorithmen berechnet werden. Bei der Methode „Einer-gegen-Alle“ werden einzelne Trennebenen für die Unterscheidung



**Abbildung 2.13:** Darstellung der Transformation von nicht trennbaren Daten aus  $\mathbb{R}^n$  (a) mittels einer Kernelfunktion nach  $\mathbb{R}^t$  (b). Die rücktransformierte Trennebene ergibt in  $\mathbb{R}^n$  eine umschließende Fläche (c).

zwischen jeder Klasse und dem jeweiligen Rest nach den genannten Verfahren bestimmt. Die Klassenzuweisung findet dann durch die SVM statt, die den höchsten Klassifikationswert erzielt. [Abe05, S. 84 f.]

Im Unterschied hierzu werden beim paarweisen Klassifizieren SVMs zwischen jedem Klassenpaar berechnet. Für die Klassifizierung werden dann die Resultate der einzelnen SVMs addiert und der Datenwert wird der Klasse mit der höchsten Anzahl an „Stimmen“ zugewiesen. Gegenüber der Einer-gegen-Alle-Methode sind die nicht klassifizierbaren Flächen reduziert. Zusätzlich ist die Berechnung einzelner Ebenen effizienter, da nur die Daten der zwei beteiligten Klassen benötigt werden und nicht das komplette Datenset. Beide Verfahren sind in Abbildung 2.14 dargestellt. [Abe05, S. 96 f., S. 123]



**Abbildung 2.14:** Trennung von drei Klassen mittels „Einer-gegen-Alle“-Klassifikation (links) und paarweiser Klassifikation (rechts). Nicht klassifizierbare Regionen sind grau hinterlegt. Die Zeichnungen sind angelehnt an [Abe05, S. 85 und S. 97].


### 2.5.3 Künstliche neuronale Netze

Neben der vorgestellten SVM können auch sogenannte künstliche neuronale Netze (KNN) zur Klassifikation verwendet werden. Diese Netze sind der biologischen Struktur im menschlichen Gehirn nachempfunden und werden aktuell häufig bei verhältnismäßig komplexen Aufgaben eingesetzt, wie beispielsweise im Bereich der Sprach- und Schrifterkennung [Sch15]. Über die erstaunliche Treffsicherheit der KNN wird auch in den Medien berichtet [Stö16], [Beu16]. Der große Vorteil dieser Netze liegt in ihrer Lernfähigkeit, die sie sehr anpassungsfähig macht und für verschiedenste Aufgaben geeignet erscheinen lässt. Die Theorie wurde in Teilen bereits 1943 von McCulloch und Pitts erarbeitet. [MP43]


Die zugrunde liegende Einheit eines künstlichen neuronalen Netzes ist ein Neuron, das seinem biologischen Ebenbild nachempfunden ist. Biologische Neuronen besitzen ein- und ausgehende Verbindungen, durch die sie über Signale bzw. Reize mit anderen Neuronen kommunizieren können. Die Neuronen selbst besitzen einen Schwellwert, ab dem sie aktiv werden. Im biologischen Fall wird die Reizschwelle durch elektrochemische Potentiale abgebildet. Eingehende Signale verändern dieses Potential und können damit eine Aktivierung des Neurons bewirken. Wenn ein Neuron aktiv wird, aktiviert es seine Ausgänge, die nun ihrerseits Einfluss auf das Potential der verbundenen Neuronen nehmen. Jedes Neuron besitzt eine individuelle Reizschwelle. Auch die Verbindungen sind nicht gleichwertig, sondern wirken sich unterschiedlich stark auf das Potential aus. [Kru+15, S. 9 ff.]

Ein Neuron bzw. ein Knoten in einem künstlichen neuronalen Netz zeichnet sich demnach vereinfacht durch eine Anzahl an Eingängen  $x_i$  und Ausgängen  $y_i$  sowie einer definierten Reizschwelle  $\Theta$  aus, ab der die Ausgänge aktiv werden. Die Reizschwelle wird dabei im einfachsten Falle durch eine um  $\Theta$  verschobene Sprungfunktion dargestellt. Darüber hinaus ist jeder Eingang  $x_i$  mit einem Gewicht  $w_i$  behaftet. Die Knoten werden aufgrund ihrer Ähnlichkeit zu den von Rosenblatt beschriebenen Modellen aus dem Bereich der Biophysik und Psychologie auch als Perzeptren bezeichnet [Ros58]. Ein beispielhaftes Neuron ist in Abbildung 2.15 zu sehen. Die Ausgabe für  $n$  Eingänge lässt sich gemäß Gleichung 2.15 in zwei Fälle unterscheiden. [Kru+15, S. 13 f.]

$$y = \begin{cases} 1 & \text{für } \Theta \leq \sum_{i=1}^n x_i w_i \\ 0 & \text{sonst} \end{cases} \quad (2.15)$$



**Abbildung 2.15:** Darstellung eines künstlichen Neurons mit zwei Eingängen und einem Ausgang. Der Ausgang wird aktiv, wenn  $1.5x_1 - 2x_2 \geq 3$  gilt.



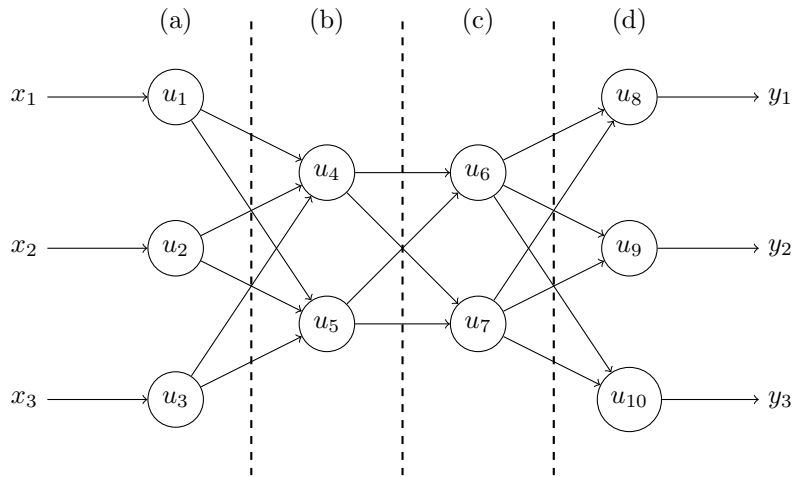
**Abbildung 2.16:** Darstellung eines KNN mit 3 Knoten

Ein künstliches neuronales Netz besteht nun aus einem Zusammenschluss mehrerer gekoppelter Neuronen, die in definierter Reihenfolge miteinander verbunden sind. Falls das Netz nur Verbindungen in eine Richtung und keine Schleifen aufweist, wird von einem vorwärts gerichteten Netz gesprochen, dargestellt in Abb. 2.16. Andernfalls handelt es sich um ein rekurrentes bzw. rückgekoppeltes Netz. Rückkopplungen werden häufig in komplexen Netzen zur Analyse von zeitlichen Signalverläufen (z.B. Video- oder Spracherkennung) genutzt. Für diese Arbeit werden nachfolgend nur vorwärts gerichtete Netze betrachtet, da die zu verarbeitenden Messwerte im Rahmen eines Verarbeitungsschritts als konstant betrachtet werden können. [Kru+15, S. 33 ff.]

Eine häufig verwendete Form von vorwärts gerichteten Netzen sind sogenannte mehrschichtige Perzeptren (engl. multilayer perceptron, MLP), deren Aufbau streng in Schichten von Neuronen eingeordnet wird. Alle Neuronen am Eingang werden zur sog. Eingangsschicht zusammengefasst. Dementsprechend gibt es auch eine Ausgangsschicht, die alle Neuronen am Ausgang des Netzes enthält. Neuronen zwischen den beiden Schichten werden in sog. verdeckte Schichten eingeteilt. Ein Beispiel ist in Abb. 2.17 zu sehen. Die Verbindungen zwischen den einzelnen Schichten werden durch eine Gewichts- oder Adjazenzmatrix  $\mathbf{W}$  dargestellt, die eine Verbindung von Neuron  $v_2$  zu Neuron  $u_3$  durch das Gewicht  $w_{u_3v_2}$  darstellt. Die Reihenfolge der Indizes  $u$  und  $v$  ist gem. [Kru+15] so gewählt, dass spätere Matrixmultiplikationen einfacher zu notieren sind. Nicht vorhandene Verbindungen sind in der Matrix mit einer 0 versehen. In Tabelle 2.2 wird eine Gewichtsmatrix für die Verbindungen zwischen der Schicht  $\mathbf{v} = \{v_1, v_2, \dots, v_m\}$  und der Schicht  $\mathbf{u} = \{u_1, u_2, \dots, u_n\}$  dargestellt, wobei  $\mathbf{v}$  vor  $\mathbf{u}$  liegt. [Kru+15, S. 45 f.]

$$\begin{array}{cccc}
 & v_1 & v_2 & \cdots & v_m \\
 u_1 & \left( w_{u_1v_1} & w_{u_1v_2} & \cdots & w_{u_1v_m} \right) \\
 u_2 & \left( w_{u_2v_1} & w_{u_2v_2} & \cdots & w_{u_2v_m} \right) \\
 \vdots & \left( \vdots & \vdots & \ddots & \vdots \right) \\
 u_n & \left( w_{u_nv_1} & w_{u_nv_2} & \cdots & w_{u_nv_m} \right)
 \end{array}$$

**Tabelle 2.2:** Adjazenzmatrix für die Schichten  $\mathbf{u}$  und  $\mathbf{v}$



**Abbildung 2.17:** Darstellung eines KNN mit einer Eingangsschicht (a), zwei verdeckten Schichten (b) und (c) sowie einer Ausgangsschicht (d), angelehnt an [Kru+15, S. 44]


Darüber hinaus kommt bei MLPs keine Sprungfunktion zum Einsatz. Stattdessen können verschiedene Aktivierungsfunktionen wie Sigmoiden oder lineare Funktionen verwendet werden (siehe Abb. 2.18). Eine mögliche Aktivierungsfunktion ist die logistische Funktion, die sich nach Gleichung 2.16 berechnet. Dabei bestimmt  $\lambda$  die Steilheit und  $\gamma$  die Grenzen des Ausgabebereiches der Funktion. Im Gegensatz hierzu hat die lineare Funktion (engl. rectified linear unit, ReLU) nur eine untere Grenze (Gl. 2.17). ReLUs kommen häufig bei CNNs mit vielen verdeckten Neuronen zum Einsatz. [Kru+15, S. 45], [vE16]

$$y = \frac{\gamma}{1 + e^{-\lambda(x-\Theta)}} \quad (2.16)$$

$$y = \max \{0, \lambda(x - \Theta)\} \quad (2.17)$$

Eine spezielle Rolle kommt dem Ausgang des KNN zu. Im Falle der Klassifizierung setzt sich dieser aus  $n$  Knoten zusammen, wobei  $n$  die Anzahl an Klassen zur Klassifizierung bezeichnet. Die Werte der einzelnen Ausgänge werden so gewählt, dass sie einer Wahrscheinlichkeit entsprechen. D.h. der Wertebereich liegt zwischen 0 und 1 und die Gesamtsumme der Ausgänge addiert sich zu 1. Eine Funktion, die diesen Anforderungen genügt, ist die normalisierte Exponentialfunktion, die auch als Softmax-Funktion bezeichnet wird. Gl. 2.18 zeigt sie für das Ausgangsneuron  $o_i$ . Die Werte  $a_i$  entsprechen den gem. Gl. 2.19 gewichteten Ausgangswerten aus den  $s$  Neuronen der vorangestellten Schicht. [Bis06, S. 196 ff.]

$$o_i = \frac{\exp(a_i)}{\sum_j^n \exp(a_j)} \quad (2.18)$$



**Abbildung 2.18:** Vergleich von drei Aktivierungsfunktionen: Sprungfunktion (a), logistische Funktion (b) und lineare Transferfunktion (c), angelehnt an [Kru+15, S. 45]

$$a_i = \sum_{v=1}^s w_{uv} o_v \quad (2.19)$$

Nachfolgend wird das Training eines MLPs vorgestellt, um es beispielsweise für die Bauteilklassifizierung anwenden zu können. Hierfür wird eine Reihe von Testdaten  $\mathbf{x}$ , für die die zu erzielenden Klassifikationen  $\mathbf{y}$  bekannt sind, in das KNN gegeben und die entsprechenden Klassifikationen berechnet. Die Abweichung zwischen dem Klassifikationsergebnis und der zu erzielenden Klassifikation wird anschließend dazu verwendet, um die Parameter in dem Netz zu optimieren. Dazu kommt das Verfahren des Gradientenabstiegs und der Fehlerrückübertragung zur Anwendung. Der genaue Vorgang des Trainings wird nachfolgend gemäß Kruse et al. [Kru+15, S. 65] beschrieben. Zuerst werden die Eingangsdaten an die erste Schicht angelegt und die Ausgabewerte  $o_i$  der enthaltenen Neuronen entsprechend den Einträgen  $x_i$  des Merkmalsvektors  $\mathbf{x}$  gesetzt:

$$o_i = x_i \quad (2.20)$$

Im nächsten Schritt werden die Ausgaben der Neuronen aus Schicht  $\mathbf{u}$  auf Basis der vorherigen Ausgaben aus Schicht  $\mathbf{v}$  gem. Gl. 2.21 berechnet.  $f$  stellt dabei die Aktivierungsfunktion des entsprechenden Neurons dar,  $s$  entspricht der Anzahl der Neuronen in Schicht  $\mathbf{v}$ . Dieser Vorgang wird für alle Schichten durchgeführt, sodass nach der Durchführung die Ausgangswerte  $\mathbf{o}_{\text{out}}$  am Ausgang des MLPs zur Verfügung stehen.

$$o_u = f\left(\sum_{v=1}^s w_{uv} o_v\right) \quad (2.21)$$

Nachdem die Ausgabewerte für alle Schichten berechnet wurden, wird der Fehlerfaktor  $\delta$  für die Ausgangsneuronen über die Abweichung des tatsächlichen Ergebnisses  $\mathbf{o}_{\text{out}}$  vom gewünschten Ergebnis  $\mathbf{y}$  berechnet (Gl. 2.22).  $\mathbf{y}$  steht für einen Vektor der Länge  $n$ , der für jedes Ausgangsneuron  $i$  das gewünschte Ergebnis  $y_i$  enthält und nur an der Stelle des Neurons, das die korrekte Klasse angibt, von Null abweicht. Bei der Berechnung des Fehlerfaktors wird zusätzlich die Ableitung der Aktivierungsfunktion in Form von  $\lambda_i$  miteinbezogen (Gl. 2.23).

$$\delta_i = (y_i - o_i)\lambda_i \quad (2.22)$$

$$\lambda_i = \frac{\partial f(a_i)}{\partial a_i} \quad (2.23)$$

Anschließend kann die Gewichtsänderung  $\Delta w_i$  gem. Gl. 2.24 berechnet werden. Die Abweichung wird zusätzlich noch mit einem Faktor  $\eta$  skaliert, der bestimmt, wie stark der Fehler in die Berechnung eingeht.

$$\Delta w_i = \eta \cdot \delta_i \cdot o_i \quad (2.24)$$

Für die Gewichtsänderung von Schichten, die nicht am Ausgang liegen, gibt es kein gewünschtes Ergebnis. Daher wird das Verfahren der Fehlerrückübertragung verwendet, bei dem die gewichteten Fehlerfaktoren  $\delta_t$  der davor liegenden Schicht  $\mathbf{t}$  mit  $p$  Neuronen zur Berechnung der aktuellen Fehlerfaktoren genutzt werden:

$$\delta_i = \left( \sum_{t=1}^p \delta_t w_{it} \right) \lambda_i \quad (2.25)$$

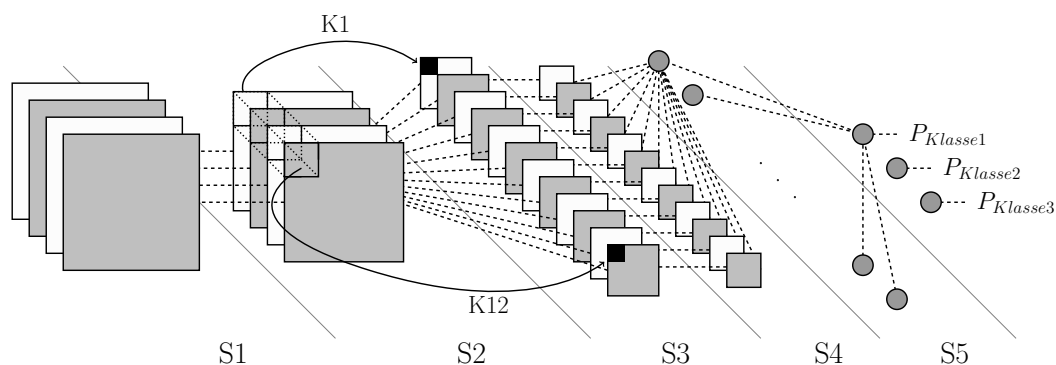
Nachdem alle Gewichte im Netz mit dem beschriebenen Verfahren korrigiert wurden, wird das Netz erneut trainiert. Dieser Vorgang läuft beliebig oft ab, bis ein Fehlerschwellwert unterschritten oder eine gewisse Anzahl an Durchläufen abgeschlossen ist. Neben der Fehlerrückübertragung gibt es noch andere Verfahren, um die Gewichtsänderung während des Trainings möglichst rasch erfolgen zu lassen. Das Momentterm-Verfahren basiert beispielsweise darauf, dass auch die Gewichtsänderung aus dem letzten Berechnungsschritt in die neue Berechnung einfließt. Damit nimmt die Gewichtsänderung gewissermaßen Fahrt auf, falls sie sich auf der Fehlerkurve steil hinab bewegt. Das Verfahren des Gewichtsverfalls wirkt sich dagegen mindernd aus, indem es die Gewichte während jedes Berechnungsschrittes um einen kleinen Faktor reduziert. Dadurch sollen zu große Gewichte verhindert werden, die dazu führen können, dass das Netz ein mögliches Fehlerminimum nicht erreicht. [Kru+15, S. 69 ff.], [Roj96, S. 168 ff.]

## 2.5.4 Convolutional Neural Network

Ein Sonderfall innerhalb der künstlichen neuronalen Netze bildet das faltende neuronale Netz (engl. convolutional neural network, CNN), das aktuell für viele Klassifikationsaufgaben verwendet wird. Das Verfahren wurde bereits Mitte der 90er Jahre entwickelt. Große Verbreitung erlangte es jedoch erst mit der Veröffentlichung von Krizhevsky et al. um das Jahr 2012. [KSH12], [LB95]

Den Eingang des CNN bildet typischerweise ein 2D-Farbbild oder ein Ausschnitt davon. Diese Bildmatrix wird in jeder Schicht innerhalb des CNN gefiltert, wobei sich die Dimensionen gemäß den eingesetzten Filtern ändern. Neben der namensgebenden Faltungsoperation (engl. convolution) werden dazu Maximum-Filter (engl. max pooling) und Nichtlinearitäten (z.B. die bereits beschriebene lineare Transferfunktion) verwendet. Vor dem Ausgang kommen typischerweise eine oder mehrere Schichten miteinander verbundener Neuronen zum Einsatz (engl. fully connected layers), die den Schichten im traditionellen KNN entsprechen. Den Ausgang selbst bilden Neuronen, die die Wahrscheinlichkeiten für die einzelnen zu detektierenden Klassen errechnen. Dazu kann die bereits erläuterte Softmax-Funktion verwendet werden.

Ein beispielhafter Entwurf mit den Schichten S1 bis S6 zum Prädizieren von drei Klassen ist in Abbildung 2.19 dargestellt. S1 und S3 bilden sich aus der Faltung der vorhergehenden Schicht mit vier (S1) bzw. zwölf (S3) verschiedenen Kernen. Die Daten für S1 werden dabei aus dem Eingangsbild ausgelesen. Die Faltung ist beispielhaft für zwei Kernel K1 und K12 dargestellt, welche zur (teilweisen) Berechnung von S3 aus S2 dienen. S2 und S4 veranschaulichen den Einsatz eines Maximum-Filters. S5 besteht aus vollverbundenen Neuronen. Deren Ausgänge werden in S6 zur Klassenprädiktion verwendet. Typische Entwürfe bestehen häufig aus einer Aneinanderreihung von mehreren Schichten, die das Eingangsbild immer weiter verkleinern und so in immer mehr einzelne Kanäle aufteilen.



**Abbildung 2.19:** Darstellung eines beliebigen CNNs. Zur Vereinfachung sind nur die Verbindungen eines Neurons für S5 und S6 eingezeichnet. Die Zeichnung ist angelehnt an eine Skizze von Peemen et al. [PMC11]

Die grundsätzliche Idee des CNN ist die schrittweise Abstraktion von lokalen bis hin zu globalen Merkmalen. Die dazu nötigen Filterparameter werden während der Trainingsphase gelernt. Je nach Aufbau des Netzes sind hierfür Parameter in den Größenordnungen von  $10^7$  oder größer zu trainieren. Die von Krizhevsky et al. vorgeschlagene Architektur besitzt z.B. 60 Millionen Parameter. Die hohe Anzahl an Parametern bringt sehr hohe Hardwareanforderungen mit sich. Die Größe aktueller Netze ist somit vor allem durch die verfügbare Hardware limitiert. Trainingsphasen von Tagen oder Wochen sind durchaus üblich. Die große Variabilität beim Entwurf hat dabei zu einer Vielzahl an verfügbaren Netzarchitekturen geführt, die für jeweils unterschiedliche Einsatzzwecke optimiert sind. Durch frei verfügbare Datenbanken wie beispielsweise das „Cityscapes Dataset“ können die einzelnen Ansätze verglichen werden. [KSH12], [Cor+16]

Konventionelle CNNs klassifizieren immer ein ganzes Bild. Um innerhalb eines größeren Bildes auftretende Komponenten bestimmen zu können, muss dieses in Unterregionen aufgeteilt werden. Girshick et al. haben für diese Problemstellung 2014 ein CNN mit einem vorgeschalteten Regionsselektionsalgorithmus beschrieben (engl. region-based CNN, R-CNN). Das R-CNN identifiziert dabei eigenständig potentielle Regionen, die Objekte enthalten könnten. Die Auswahl der Regionen findet dabei anhand einer sog. selektiven Suche (engl. selective search) statt. Bei Anwendung einer selektiven Suche werden zuerst die sich in Farbe und Helligkeit gleichenden aneinander hängenden Regionen identifiziert. Anschließend werden die Übereinstimmungen der identifizierten Regionen berechnet und die Regionen verworfen, deren Übereinstimmung zu hoch ist. Die übrig bleibenden Regionen werden an das CNN zur Klassifizierung weitergeleitet. Falls eine Region als positiv klassifiziert wurde, wird ein Rechteck mit den Maßen der Region in das große Originalbild an der entsprechenden Position abgespeichert. Im Anschluss findet eine Fusion von stark überlappenden Klassifizierungsrechtecken statt. [Gir+14], [Uij+13]

### 2.5.5 Random Forest

Das Zufallswald-Klassifikationsverfahren (engl. random forest, RF) basiert auf einzelnen Entscheidungsbäumen (engl. decision tree, DT) und wurde 2001 von Breiman vorgestellt. Zur Erläuterung des Verfahrens wird zunächst auf die Entwicklung eines Entscheidungsbaums eingegangen, der von Quinlan 1986 vorgestellt wurde. [Bre01], [Qui86]

Ein häufig genanntes Beispiel zur Veranschaulichung der Arbeitsweise eines DT ist die Bestimmung, ob ein Tennisspiel stattfindet oder nicht. Dazu werden die kategorischen Wetterdaten (nachfolgend als Merkmale bezeichnet) bei früheren Sportereignissen zu Rate gezogen (Tabelle 2.3). Zur Überführung in einen Entscheidungsbaum werden alle möglichen Varianten jedes Merkmals, z.B. „sonnig“, „bewölkt“ und „regnerisch“ für das Merkmal Wetter, zu einem Entscheidungsknoten aufgetragen und mit anderen Knoten verbunden. Ein vollständiger Baum für das Sportereignispro-

| Tag | Wetter     | Luftfeuchtigkeit | Wind    | Spiel |
|-----|------------|------------------|---------|-------|
| 1   | sonnig     | hoch             | schwach | nein  |
| 2   | sonnig     | hoch             | stark   | nein  |
| 3   | neblig     | hoch             | schwach | ja    |
| 4   | regnerisch | hoch             | schwach | ja    |
| 5   | regnerisch | normal           | schwach | ja    |
| 6   | regnerisch | normal           | stark   | nein  |
| 7   | neblig     | normal           | stark   | ja    |
| 8   | sonnig     | hoch             | schwach | nein  |
| 9   | sonnig     | normal           | schwach | ja    |
| 10  | regnerisch | normal           | schwach | ja    |
| 11  | sonnig     | normal           | stark   | ja    |
| 12  | neblig     | hoch             | stark   | ja    |
| 13  | neblig     | normal           | schwach | ja    |
| 14  | regnerisch | hoch             | stark   | nein  |

**Tabelle 2.3:** Daten früherer Sportereignisse, entnommen (ohne Temperatur) aus [Qui86, S. 86]

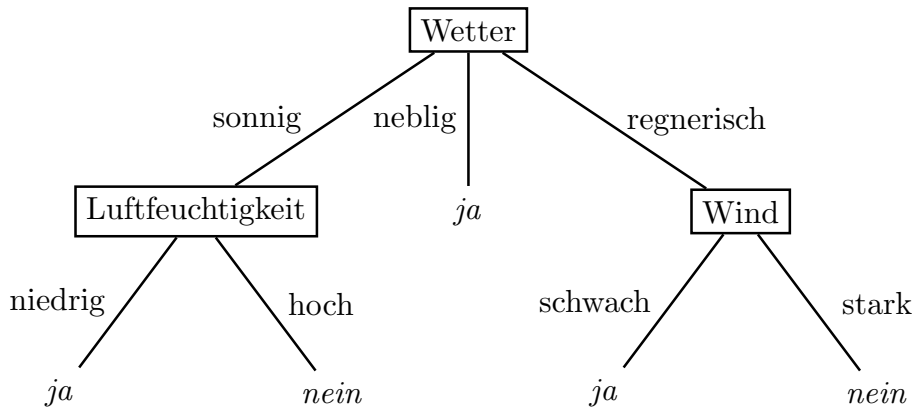
blem ist in Abb. 2.20 dargestellt. Da es sich bei diesem Problem um eine Entscheidung zwischen den zwei Klassen *ja* (Spiel findet statt) und *nein* (Spiel findet nicht statt) handelt, sind die Ausgänge des Baumes entsprechend immer einer der zwei Klassen zugeordnet. [Qui86]

Ausgehend von dem Entscheidungsbaum in Abb. 2.20 stellt sich nun die Frage, wie bestimmt wird, welcher Knoten wann zur Datenaufteilung genutzt wird. Quinlan schlägt als Maß zur Auswahl die Berechnung der Änderung der Shannon-Entropie vor. Die Entropie, ursprünglich eine physikalisch definierte Größe zur Angabe des Maßes der Unordnung eines Systems, bestimmt nach Shannon den Informationsgehalt von Daten. Zur Berechnung wird zuerst die Wahrscheinlichkeit  $p_i$ , eine Klasse  $i$  in einem Datensatz der Menge  $m$  mit  $n$  Klassen anzutreffen, eingeführt:

$$p_i = \frac{m_i}{m} \quad (2.26)$$

$m_i$  steht dabei für die Anzahl an Objekten der Klasse  $i$  in der Menge  $m$  aller Klassen. Beispielsweise entspricht die Wahrscheinlichkeit, die Klasse „findet statt“ in dem (ungeteilten) Datensatz aus Tab. 2.3 zu finden, dem Wert  $p_{\text{findet statt}} = \frac{9}{14} \approx 0,643$ . Dieser Wahrscheinlichkeit wird nun der Informationsgehalt  $I(p_i) = -\log_2(p_i)$  zugeordnet. Damit lässt sich die Entropie  $H$  gem. Gl. 2.27 berechnen. [Sha48]

$$H = \sum_{i=1}^n p_i I(p_i) = - \sum_{i=1}^n p_i \log_2(p_i) \quad (2.27)$$



**Abbildung 2.20:** Entscheidungsbaum für das Sportereignisproblem, nach [Qui86, S. 87]

Die Entropie für die aufgeteilten Daten entspricht den gewichteten Einzelentropien in den Unterkategorien des Merkmals, womit sich die Entropieänderung nach Quinlan gem. Gl. 2.28 ergibt.

$$\Delta H = H - \sum_a \frac{m_a}{m} \sum_{i=1}^n p_{i,a} \log_2(p_{i,a}) \quad (2.28)$$

Dabei entspricht  $m_a$  der Anzahl aller Objekte in der Untergruppe  $a$  und  $p_{i,a}$  der Auftrittswahrscheinlichkeit von Klasse  $i$  in der Untergruppe  $a$ .  $n$  gibt die Anzahl der vorkommenden Klassen an. Die vorgestellte Entropieänderung wird nun für jede Knotenbildung herangezogen und das Merkmal gewählt, welches den größten Informationsgewinn ermöglicht. Anzumerken ist dabei, dass die Verwendung des selben Merkmals zur Trennung mehrmals hintereinander durchaus vorkommen kann.

Um mit dem beschriebenen Verfahren auch numerische Merkmale zur Trennung verwenden zu können, werden diese Merkmale nach ihrer Größe geordnet und Einteilungen in Form des Mittelwerts benachbarter Merkmale gebildet. Diese Grenzen können anschließend gem. Gl. 2.28 auf den größten Informationsgewinn hin untersucht werden. [Qui86]

Mit dem beschriebenen Verfahren lassen sich Trainingsdaten beliebig genau trennen. Theoretisch bricht das Verfahren erst dann ab, wenn in jeder Unterkategorie nur noch eine Klasse vorkommt. Dabei wird der Baum jedoch sehr groß und es kommt zur sogenannten Überanpassung. D.h. der Baum hat die Trainingsdaten so genau angelernt, dass er die Fähigkeit zur Generalisierung der Daten verloren hat. Verglichen mit einem kleineren Baum resultiert daraus letztlich eine schlechtere Klassifikation. Zur Vermeidung dieses Problems können viele Methoden verwendet werden. Eine einfache Möglichkeit zur Verhinderung der Überanpassung ist die Einführung ei-

nes Grenzwerts in Form eines minimalen Informationsgewinns durch eine Trennung. Wird dieser unterschritten, wird kein neuer Knoten hinzugefügt, sondern die häufigste Klasse in dem aktuellen Ast als Klassifikationsergebnis festgelegt. Ein weiteres Verfahren basiert auf dem gezielten Entfernen einzelner Knoten (engl. pruning). Dazu wird der Baum zuerst mit Trainingsdaten vollständig trainiert (Klassifikation zu 100 %). Nach dem Training werden die Testdaten verwendet, um den Baum zu optimieren. Schritt für Schritt werden nun einzelne Knoten entfernt. Falls sich dabei die Klassifikationsrate verbessert, wird der Knoten weggelassen. [Qui92]


Im RF kommen nun eine Anzahl  $k$  dieser Entscheidungsbäume zum Einsatz, die jeweils individuell eine Klassifizierung durchführen. Die Zuordnung einer Klasse geschieht dann durch Mehrheitsentscheid. Die einzelnen Bäume werden jeweils mit einer individuellen, zufälligen Auswahl an Trainingsdaten angelernet. Damit gleicht das Verfahren sehr der sog. Bagging-Methode, auf deren Basis es entwickelt wurde. Darüber hinaus wird außerdem die Auswahl der Merkmale an einzelnen Knoten variiert, die der Baum zur Trennung verwenden darf. Im Unterschied zum einzelnen Entscheidungsbaum wird im RF kein pruning verwendet, weil die dadurch bleibende Überanpassung im einzelnen Baum durch die Vielzahl der verwendeten Bäume wieder abgeschwächt wird. Alternativ kann jedoch die Anzahl der Entscheidungsebenen bzw. die Baumgröße beschränkt werden. [Bre96], [Bre01]

## 2.5.6 Verfahren zur Bewertung einzelner Klassifikationsergebnisse

Um die Ergebnisse eines Klassifikators für Mehrklassensysteme vergleichen zu können, wird dieser zur Klassifikation von Testdaten verwendet. Das Ergebnis wird in der sog. Wahrheitsmatrix dargestellt (Beispiel in Tabelle 2.4). Die Hauptdiagonale der Matrix zeigt dabei die Anzahl der Datensätze aller Klassen, die korrekt erkannt wurden, an. Diese werden auch als echt positiv (engl. true positive, TP) bezeichnet. Falls ein Datensatz einer Klasse  $a$  jedoch fälschlicherweise als Klasse  $b$  prädiziert wurde, wird er in die Spalte von  $b$  eingetragen. Aus der Sicht von Klasse  $b$  handelt es sich dabei um eine sog. Falsch-Positiv-Detektion (engl. false positive, FP).

| Klasse 1 | Klasse 2 | Klasse 3 | ← klassifiziert als |
|----------|----------|----------|---------------------|
| 12       | 0        | 2        | Klasse 1            |
| 3        | 15       | 0        | Klasse 2            |
| 1        | 2        | 11       | Klasse 3            |

**Tabelle 2.4:** Beispielhafte Wahrheitsmatrix für drei Klassen. Drei Objekte der Klasse 2 wurden fälschlicherweise als Objekt der Klasse 1 erkannt.



**Abbildung 2.21:** Beispielhafte ROC-Kurven

Ausgehend von der Wahrheitsmatrix können weitere Werte zur Beurteilung der Klassifikation berechnet werden. Ein häufig verwendetes Maß ist die Erkennungsrate, die dem Verhältnis der korrekt erkannten Datensätze zu deren Gesamtanzahl entspricht. Die gesamte Erkennungsrate beträgt somit für den in Tabelle 2.4 beschriebenen Fall  $\frac{12+15+11}{12+2+3+15+1+2+11} = 82,6\%$ . Daneben werden auch sog. Grenzwertoptimierungskurven (engl. receiver operating characteristics, ROC) verwendet. Die ROC-Kurven entsprechen einem Diagramm, in dem die TP-Rate über der FP-Rate normiert aufgetragen wird. Die TP-Rate entspricht dem Verhältnis der korrekt klassifizierten positiven Klassenobjekte (TPs) zur Anzahl aller positiven Klassenobjekte. Dementsprechend stellt die FP-Rate das Verhältnis aller fälschlicherweise als positiv klassifizierten negativen Klassenobjekte (FPs) zur Anzahl aller negativen Klassenobjekte dar. Typischerweise werden mit dem Zulassen einer höheren FP-Rate auch mehr TPs detektiert. Das Optimum liegt oben links im Diagramm, was einer hohen TP-Rate ohne FPs entspricht. Zur Berechnung der ROC-Kurve wird der Schwellwert in dem Klassifikator variiert, der die Trennung zwischen FPs und TPs übernimmt. Zur einfacheren Darstellung werden die Kurven ggf. integriert und die Fläche unter der Kurve (engl. area under the curve, AUC) als Kenngröße verwendet. Beispiele für ROC-Kurven sind in Abbildung 2.21 dargestellt. [Faw06]

Ein weiteres, wichtiges Maß ist der Cohens-Kappa-Koeffizient  $\kappa$ , der die zufällige Übereinstimmung von Prädiktion und Realität zur Evaluierung miteinbezieht. Er berechnet sich gem. Gl. 2.29. Dabei steht  $p_o$  für den Anteil von tatsächlich beobachteter Übereinstimmung (Gl. 2.30) und  $p_c$  für die zufällige Übereinstimmung (Gl. 2.31).  $w_{ij}$  entspricht dem Eintrag in Zeile  $i$  und Spalte  $j$  der zugrunde liegenden Wahrheitsmatrix.  $N$  ist die Gesamtanzahl an Objekten in der Wahrheitsmatrix. [Coh60]

$$\kappa = \frac{p_o - p_c}{1 - p_c} \quad (2.29)$$

$$p_o = \frac{\sum_{i=1}^k w_{ii}}{N} \quad (2.30)$$

$$p_c = \frac{1}{N^2} \sum_{i=1}^k \left( \sum_{j=1}^k w_{ji} \cdot \sum_{j=1}^k w_{ij} \right) \quad (2.31)$$

Der Wert von  $\kappa$  ist umso höher, je kleiner die Randsummen der Wahrheitsmatrix sind. Im Normalfall liegt der Wertebereich zwischen 0 und 1, wobei 0 dem Zufall und 1 einer optimalen Klassifikation entspricht. Werte kleiner 0 können bei sehr schlechten Ergebnissen ebenfalls vorkommen.



### 3 Analyse des Elektroschrotts

In diesem Kapitel wird der Aufbau einer Datenbank beschrieben, die für das Training der Detektionsalgorithmen verwendet wird. Dazu wurden verschiedene Chargen EAG aus mehreren Quellen akquiriert. Hauptsächlich wurde Schrott einer lokalen Sammelstelle und des Rechenzentrums der Hochschule Aschaffenburg herangezogen, ebenso eine Fraktion eines Recyclingunternehmens. Der Fokus lag dabei auf Computerhardware. Weiterhin konnte auch Schrott der Fraunhofer-Projektgruppe für Wertstoffkreisläufe und Ressourcenstrategie IWKS untersucht werden. Die einzelnen Fraktionen sind in Tabelle 3.1 genauer erläutert. Die Zusammensetzung und auch die Verschmutzung der einzelnen Schrotte ist sehr heterogen. Etwa 50% der untersuchten Rechner waren darüber hinaus nicht vollständig, insbesondere Festplatten wurden kaum angetroffen. Die Rechner der Hochschule waren teilweise identisch, ebenso die Bildschirme. Die genaue Zusammensetzung in Materialgruppen ist dem Anhang auf Seite 91 zu entnehmen.

Im nächsten Schritt wurden aus dem gesammelten Elektroschrott, falls nötig, hochwertige Leiterplatten manuell extrahiert. Diese wurden mit dem in Kapitel 4 beschriebenen Aufbau vermessen und die gewonnenen 2D- und 3D-Daten aufgezeichnet. Insgesamt wurden von mehr als 100 Leiterplatten über 400 einzelne Messungen aufgenommen. Dazu wurde jede Leiterplattenseite, falls sie mit Bauteilen bestückt war, in mindestens zwei Orientierungen aufgenommen. Leiterplatten mit Tantal-Bestückung wurden in vier Orientierungen vermessen.

Für die Tests der Software und das Training der Klassifikatoren wurden die auf den Leiterplatten vorkommenden Bauteile in die zu detektierenden Klassen eingeteilt.

| Quelle               | Zusammensetzung                       | Verschmutzung    |
|----------------------|---------------------------------------|------------------|
| Sammelstelle         | 9 Desktoprechner inkl. Gehäuse        | teilweise stark  |
| Hochschule           | 8 Rechner und ca. 15 Bildschirme      | sehr gering      |
| Recyclingunternehmen | 13 Leiterplatten aus Notebooks        | vereinzelt stark |
| IWKS                 | Leiterplatten aus div. Bereichen      | sehr gering      |
| Internet             | 47 identische Grafikkarten (Bj. 1999) | sehr gering      |

**Tabelle 3.1:** Zusammensetzung des untersuchten Elektroschrotts

Die Klassen wurden dabei nach Funktionstyp und Sinnhaftigkeit in einem längeren Prozess erarbeitet. Grundsätzlich erlaubt eine größere Anzahl an Klassen eine genauere Beurteilung der Leiterplattenkomponenten. Gleichzeitig verschlechtert sich jedoch die Erkennungsrate, da die Klassifizierungsaufgabe komplizierter wird. Die im Rahmen dieser Arbeit erarbeiteten Klassen stellen daher einen Kompromiss dar und sind in Tabelle 3.2 zusammengefasst.


Im letzten Schritt erfolgte das zeitlich sehr aufwendige manuelle Markieren der Bauteile in den Rohdaten einschließlich der genauen Positionsdaten, Abmessungen und der entsprechenden Klassenzugehörigkeit. Dazu wurde ein entsprechendes Softwarewerkzeug entwickelt, dessen Resultat in Abb. 3.1 veranschaulicht ist. Insgesamt konnten 13737 Bauteile vermessen werden. Die so gewonnenen Klassen- und Positionsdaten (engl. ground truth, GT) bilden die Grundlage für die unter Abschnitt 5 beschriebenen Auswertungen.

Als problematisch erwiesen sich hier insbesondere Bauteile, die kein Bauteil im eigentlichen Sinn sind, wie z. B. Kühlerhalterungen oder abstehende Kabelreste. Bauteile dieser Art wurden der Klasse „Unklassifiziert“ zugeordnet, die auch Fehlmessungen beinhaltet. Darüber hinaus sind Bauteile problematisch, die teilweise durch andere verdeckt sind oder die im Rahmen ihrer Klasse besonders ungewöhnlich er-

| Klasse          | Anzahl | Beschreibung                                |
|-----------------|--------|---|
| IC              | 3533   | schwarze ICs, vorrangig SMT                 |
| asym. IC        | 698    | größere ICs wie Linearwandler, THT & SMT    |
| BGA             | 118    | ICs mit Anschlüssen in Kugelgitteranordnung |
| Elko            | 1798   | Elektrolytkondensatoren, vorwiegend THT     |
| Tantal gelb     | 560    | gelbe Tantalkondensatoren, SMT              |
| Tantal orange   | 111    | orange Tantalkondensatoren, SMT             |
| Tantal schwarz  | 1.366  | schwarze Tantalkondensatoren, SMT           |
| Quarz           | 271    | Quarzoszillatoren, THT                      |
| Stecker         | 1223   | externe Anschlüsse, THT                     |
| Pins            | 338    | Pinleisten, THT                             |
| Buchse          | 615    | Buchsenleisten, THT                         |
| Spule           | 128    | Ringkerndrosseln, meist liegend             |
| Trafo           | 431    | quaderförmige Trafos, SMT                   |
| Kühler          | 94     | Kühleinheiten auf Prozessoren               |
| Batterie        | 27     | Lithiumbatterien auf Mainboards             |
| Batterie-Sockel | 22     | leere Batteriehalter                        |
| CPU             | 53     | große Prozessoren                           |
| CPU-Sockel      | 73     | leere Prozessorhalter                       |
| Unklassifiziert | 2278   | Fehlmessungen, restl. Bauteile              |
| Gesamt          | 13737  |   |

**Tabelle 3.2:** Aufschlüsselung der Leiterplattenbauteile in Klassen

scheinen, beispielsweise ICs mit glänzendem Aufkleber. Diese sind in der Datenbank mit einem speziellen Vermerk ausgestattet und wurden in dieser Arbeit nicht für weitere Tests verwendet. Von den in Tabelle 3.2 aufgezählten Komponenten fallen etwa 1000 Stück in diese Kategorie.



**Abbildung 3.1:** Resultat der manuellen Markierung von Leiterplatten. Dargestellt ist die Farbaufnahme der Leiterplatte als Referenz (oben) und das zugehörige Höhenprofil in Falschfarben mit den markierten Komponenten (unten). Jedes markierte Feld beinhaltet mindestens ein Bauteil. Freiliegende Komponenten sind mit grünem, problematische bzw. zusammengewachsene Bauteile mit rotem Overlay dargestellt.



# 4 Experimenteller Aufbau einer Detektionsanlage

Im folgenden Kapitel wird der experimentelle Aufbau der Anlage dargestellt und ein Einblick in die Steuerungseinheiten und die verwendeten Sensoren gegeben.

Der Aufbau dient der Durchführung einer Machbarkeitsstudie für die industrielle Entstückung bzw. Wiedergewinnung von HT-Metallen und anderen wertvollen Materialien aus Elektroschrott. Der experimentelle Aufbau sollte dabei die Untersuchung grundsätzlicher Fragestellungen zu Echtzeitfähigkeit, Durchsatz und Detektionsrate ermöglichen. Der durchschnittliche Preis von Leiterplatten im Elektroschrott liegt zwischen wenigen Cent bis etwa 10€ je Kilogramm<sup>4</sup> im Ankauf bei Margen von bis zu 1 t. Moderne Recyclingbetriebe setzen daher Elektroschrott im Bereich von etwa 100000 t pro Jahr um, um wirtschaftlich handeln zu können<sup>5</sup>. Um diesem Anspruch gerecht zu werden, sieht das Konzept von Anfang an ein Förderband vor, das den Sensoren eine kontinuierliche Aufzeichnung von Messdaten ermöglicht und somit nah am Industrieumfeld ist. Auch bei der Wahl der Sensoren wurde auf eine kontinuierliche Datenakquisition, die mit dem Förderband schritthält, Wert gelegt.

Neben dem Einsatz eines Förderbands sollte eine Sensorkombination die parallele Aufnahme von 2D- und 3D-Daten ermöglichen. Ausgehend vom Vergleich der verschiedenen Technologien für 2D- und 3D-Systeme (Abschnitt 2.2) wurde die Verwendung einer 2D-Kamera und eines 3D-Laserscanners festgelegt. Abbildung 4.1 zeigt das Gesamtkonzept der Anlage. Der fertige Aufbau zur Bauteildetektion ist in Abbildung 4.2 näher erläutert.

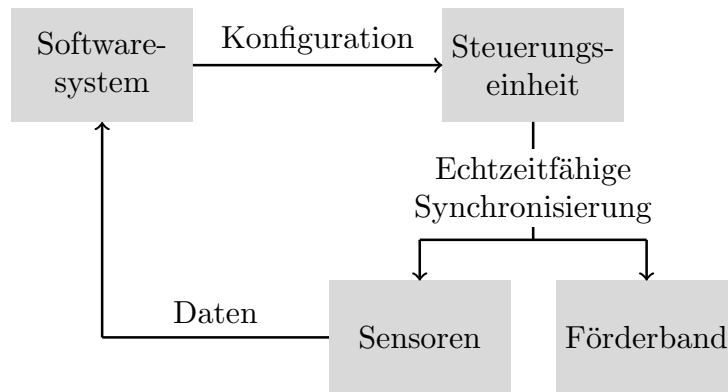
## 4.1 Zentrale Steuerungseinheit

Die komplette Anlage wird über eine zentrale Steuerungseinheit verwaltet. Ihr wesentlicher Zweck ist die Synchronisation zwischen Förderband und Sensoren. Diese muss in Echtzeit ablaufen, da ansonsten die Integrität der Messdaten gefährdet ist.


---

<sup>4</sup>Die genannten Preise wurden der online einsehbaren Preistabelle der ESG Edelmetall-Service GmbH & Co. KG im Juli 2017 entnommen.

<sup>5</sup>Diese Zahl wurde durch die Recherchen des Autors im Rahmen der Arbeit ermittelt.



**Abbildung 4.1:** Konzeption der Anlage



**Abbildung 4.2:** Aufbau zur Detektion


Um diese Echtzeitfähigkeit sicherzustellen, kommt ein Mikrocontroller zum Einsatz, der mit entsprechender Software ausgestattet ist. Das Steuerungssystem lässt sich über eine serielle Schnittstelle (RS-232) konfigurieren. Damit ist die Abstimmung der Aufnahmefrequenz der Sensoren für unterschiedliche Datenaufösungen möglich. Die Synchronisation der Sensoren mit dem Förderband ist mit einem Geber sichergestellt. Dieser Geber löst etwa alle 350  $\mu\text{m}$ , die das Förderband verfährt, einen Puls aus, der von dem Mikrocontroller erkannt wird. Verschiedene Vielfache dieser Pulse werden an die Triggereingänge der Sensoren weitergeleitet und lösen synchrone Aufnahmen von Messdaten aus.

Die Steuerungseinheit und der Einsatz der seriellen Schnittstelle sind das Resultat aus verschiedenen Ansätzen<sup>6</sup>, bei denen unter anderem ein Raspberry Pi zur Kommunikation via Ethernet genutzt werden sollte. Dieses erwies sich jedoch als nicht echtzeitfähig, weshalb der erwähnte Mikrocontroller zum Einsatz kommt.

## 4.2 Kamera AVT Prosilica GT2050C

Bei der eingesetzten Kamera handelt es sich um das Modell Prosilica GT2050C des Herstellers Allied Vision Technologies GmbH. Sie bietet eine Auflösung von 2048 Pixel in x- und y-Richtung bei einer Aufnahmegeschwindigkeit von 28,6 FPS. Die Geschwindigkeit der Kamera kann gesteigert werden, falls nur ein Teil des Gesamtbilds ausgelesen wird. Eine Reduktion auf 2 x 2048 Pixel ermöglicht z.B. laut Herstellerangabe eine Aufnahmegeschwindigkeit von 4926,1 FPS. [All17, S. 63]

Die Prosilica GT2050C verfügt über drei verschiedene Kanäle für Rot, Grün und Blau. Die spektrale Empfindlichkeit reicht dabei bis in den Nah-Infrarot-Bereich hinein, wie auf Abb. 4.3 zu sehen ist. Dieser Bereich wurde für spektroskopische Tests mit Infrarot-Leuchtdioden eingesetzt, die in Abschnitt 4.4 beschrieben sind.




**Abbildung 4.3:** Spektrale Empfindlichkeit der eingesetzten Kamera, entnommen aus einem Datenblatt der Prosilica GT2050C von AVT [AS15]

<sup>6</sup>Das Hardwarelayout der Steuerungseinheit und deren Programmierung wurde in Zusammenarbeit mit Marco Ziemen umgesetzt. [Zie17]

Wie bei jeder Verwendung von optischen Messinstrumenten ist auch beim Einsatz der Prosilica GT2050C eine dem Einsatzzweck entsprechende Beleuchtung wichtig. Insbesondere sollten Verschattungen von Bauteilen auf den Leiterplatten vermieden werden, da diese zur Beeinträchtigung der Bildverarbeitungsalgorithmen führen können. Auch Glanzlichter, wie sie bei der intensiven, direkten Beleuchtung von stark reflektierenden Oberflächen entstehen, sollten vermieden werden. Aus diesem Grund wurde eine leistungsstarke Beleuchtungsglocke zur diffusen Beleuchtung aufgebaut. Diffus bedeutet in diesem Zusammenhang die Abwesenheit einer Vorzugsrichtung, mit der das Licht die Quelle verlässt. Stattdessen trifft es von allen Seiten auf das Messobjekt auf. [BPF12, S. 291 f.]

Als Lichtquellen kommen etwa 150 weiße Hochleistungsleuchtdioden (engl. light-emitting diode, LED) mit einer Einzelleistung von bis zu 2 W zum Einsatz, die in eine Aluminiumhalbkugel hineinleuchten. Die LEDs sind zur Kühlung auf einem 1 cm dicken Aluminiumring mit einem Innendurchmesser von 50 cm angebracht<sup>7</sup>. Die hohe Lichtintensität ermöglicht entsprechend kurze Belichtungszeiten der Kamera, womit Verwacklungen durch die Bewegung des Förderbands entgegenwirkt wird. Neben der Lichtintensität eignen sich die ausgewählten LEDs besonders für den vorgestellten Zweck, weil sie aufgrund der langen Lebensdauer und hohen Robustheit gegenüber Vibrationen auch gut in Industrieanlagen eingesetzt werden können. Auch das abgestrahlte Spektrum ist gegenüber anderen Quellen verhältnismäßig homogen. Abbildung 4.4 veranschaulicht die Funktionsweise. [Hor06, S. 98]




**Abbildung 4.4:** Funktionsweise der aufgebauten Beleuchtungseinheit

### 4.3 Laserscanner LMI Gocator 2370


Der Gocator 2370 ist ein Modell des kanadischen Herstellers LMI Technologies Inc. und arbeitet gemäß dem Triangulationsprinzip, das in Abschnitt 2.2 erläutert wurde. Die Wellenlänge des eingesetzten Lasers entspricht 660 nm. Da der Scanner innerhalb eines Labors ohne besondere Vorkehrungen eingesetzt werden soll, wurde ein Modell mit der Laserschutzklasse 2M erworben. Der in dem Gocator eingebaute Laser besitzt deshalb eine geringere Intensität, woraus sich eine Verringerung der praktisch einsetzbaren Aufnahmefrequenz ergibt. Im Hinblick auf den prototypischen Entwurf der Anlage ist das jedoch vernachlässigbar. Theoretisch erlaubt der Sensor eine Abtastrate von bis zu 5000 Hz. In der Anlage wird er mit etwa 100 Hz betrieben. Durch das Messprinzip bedingt ergibt sich je Messung eine komplette Höhenlinie.

<sup>7</sup>Die Beleuchtungsglocke wurde in Zusammenarbeit mit Heinz-Xaver Hesch aufgebaut. [Hes15]



**Abbildung 4.5:** Veranschaulichung der Interpolation der Höhenmesswerte. Der Linienelementabstand  $\Delta y$  ist abhängig von der Geschwindigkeit des Förderbands und der Aufnahme­frequenz.  $\Delta x_1$  und  $\Delta x_2$  kennzeichnen den Messpunkt­abstand innerhalb einer Linie ohne bzw. mit Interpolation.


Um die Daten später auswerten zu können, sind äquidistante Messabstände in x- und y-Richtung nötig. Andernfalls würde ein Objekt verzerrt erscheinen. Das bedeutet im vorliegenden Fall, dass die Auflösung der durch den Sensor aufgenommenen Höhenlinien so interpoliert wird, dass sie zu der feststehenden Fahrgeschwindigkeit des Förderbands bzw. der Aufnahme­frequenz der Höhenlinien passt (Abb. 4.5). Konkret wurde ein Messpunkt­abstand von  $344\ \mu\text{m}$  in x- und y-Richtung festgelegt. Diese Auflösung wurde durch entsprechende Kalibration mit einem runden Kalibrations­objekt ermittelt. Falls die Taktrate des Sensors nicht zur Auflösung in x-Richtung passt, erscheint das eigentlich runde Kalibrations­objekt verformt. Ein Mess­beispiel für fehlerhafte und korrekte Kalibration ist in Abb. 4.6 zu sehen.



**Abbildung 4.6:** Messung mit fehlerhafter (links) und korrekter (rechts) Kalibration

## 4.4 Spektroskopiehalbkugel

Im Rahmen der vorliegenden Arbeit wurde zudem ein vielversprechender Ansatz auf Basis der Materialdetektion mittels optischer Spektroskopie überprüft (siehe Abschnitt 2.2.2). Die dazu ursächliche Veröffentlichung von Gu und Liu behandelt die Unterscheidung von verschiedenen Stählen mittels optischer Spektroskopie im visuellen Bereich mit einigem Erfolg [GL12]. Zur Messung der nötigen Daten wird von Gu und Liu ein halbkugelförmiger Aufbau eines Rahmens beschrieben, der an spezifischen Positionen über LED-Cluster verfügt. Diese strahlen Licht einer definierten Wellenlänge mit einem definierten Einfallswinkel auf das zu messende Objekt. Eine



**Abbildung 4.7:** Durch die Spektroskopiehalbkugel abgedeckte Wellenlängenbereiche. Die Intensitäten der eingesetzten LEDs auf der y-Achse sind normiert dargestellt.

Kamera in der Mitte des Aufbaus nimmt dabei das reflektierte Licht auf. Mit den so erzeugten Messwerten konnten anschließend verschiedene Materialien relativ gut klassifiziert werden. [GL12], [LYG13]

Im Rahmen dieser Arbeit wurde daher ein ähnlicher Aufbau in Form eines halbkugelförmigen Gitterrahmens entwickelt<sup>8</sup>. An diesem Rahmen wurde in fünf verschiedenen Winkeln jeweils die gleiche Auswahl an LEDs angebracht, die zusammen einen Wellenlängenbereich von 400 nm bis etwa 900 nm abdecken. Die dazu ausgewählten 13 schmalbandigen LEDs wurden zusätzlich durch eine weiße LED ergänzt, die einen größeren Bereich abdeckt. Die einzelnen LED-Spektren sind in Abbildung 4.7 normiert dargestellt. Die Einfallswinkel, die zwischen dem vom LED-Cluster abgegebenen Licht und dem Lot auf die zentrale Messfläche am Boden eingeschlossen werden, sind in Tabelle 4.1 aufgeführt. Durch die räumliche Ausdehnung der LED-Cluster besitzen die einzelnen LEDs einen eigenen Einfallswinkel, der um wenige Grad von dem gemessenen Winkel abweicht. Mit diesem Aufbau kann gegenüber der von Kleber und Kampel beschriebenen Untersuchung auch der Einfluss der Einfallswinkel untersucht und zur Klassifizierung mit herangezogen werden [KK15a].

Zur Kompensation der unterschiedlichen Helligkeiten der eingesetzten LEDs in Kombination mit der spektralen Empfindlichkeit der verwendeten Kamera (AVT Prosilica GT2050C) wurden Testaufnahmen einer weißen Oberfläche durchgeführt und individuelle Belichtungszeiten für jede Leuchtdiode eingestellt. Diese variieren zwischen 5,5 s und 25 s. Zur Abdunklung und Verhinderung von Umwelteinflüssen wurde ein spezieller Verdunklungsstoff über den Aufbau gelegt. Für die Messung wurde für jede LED in jedem Cluster eine einzelne Aufnahme mit der zuvor gemessenen Belichtungszeit aufgenommen, insgesamt also 70 Aufnahmen mit jeweils drei Farbkanälen.

| LED-Cluster    | 1   | 2   | 3   | 4   | 5   |
|----------------|-----|-----|-----|-----|-----|
| Einfallswinkel | 19° | 28° | 44° | 55° | 73° |

**Tabelle 4.1:** Einfallswinkel der eingesetzten LED-Cluster

<sup>8</sup>Der Aufbau der Spektroskopiehalbkugel erfolgte in Zusammenarbeit mit Christian Kohlbrenner. [Koh16]

# 5 Echtzeitfähiges Softwaresystem zur Bauteilerkennung

Dieses Kapitel beschäftigt sich mit dem im Rahmen der Arbeit entwickelten Softwaresystem, das die automatisierte Erkennung von Leiterplattenkomponenten übernimmt. Der Aufbau und das Design des Systems werden schrittweise erläutert. Zur Optimierung wurden weiterhin über 250 Tests mit der kompletten Datenbank durchgeführt, von denen die wichtigsten einschließlich der Ergebnisse hier beschrieben sind.

Im Gesamtüberblick befindet sich die Software hinter dem Sensorsystem, dessen Ausgangsdaten von dem System eingelesen werden. Die Ausgabe des Systems umfasst detektierte Komponenten, die relativ zur Platinenposition angezeigt oder zwischengespeichert werden können. Die Ausgabe kann auch an eine prototypische Anlage zur Bauteilextraktion weitergereicht werden, wie sie in Kapitel 6 beschrieben wird. Die Anforderungen an das System wurden zu Beginn der Entwicklung festgelegt:

- Echtzeitfähige Messungen und schritthaltende Verarbeitung
- Parallelisierte und modulbasierte Strukturen
- Nutzung von Standard-Bildverarbeitungsbibliotheken
- Möglichkeit des „Online“- und des Datenbankbetriebs
- Parametrierbar mittels Konfigurationsdatei
- Steuerbar über Terminaleingaben

## 5.1 Systemaufbau

Insbesondere die Echtzeitfähigkeit stellte eine wichtige Anforderung dar. Um diese zu erfüllen, wurde das System in C++ in Kombination mit einer Parallelisierung durch C++11-Threads entwickelt. Jeder Thread stellt dabei ein Modul dar. Diese Module


lassen sich in die Bereiche Vorverarbeitung, Segmentierung, Merkmalsextraktion und Klassifizierung aufteilen. Die einzelnen Bereiche sind nachfolgend im Detail beschrieben<sup>9</sup>.

### 5.1.1 Vorverarbeitung

Innerhalb der Vorverarbeitung werden mehrere Schritte durchgeführt, die der Optimierung und Aufbereitung der Messdaten dienen. Sensordaten des Linienscanners und der Kamera werden zeitlich synchronisiert und zueinander kalibriert. Darüber hinaus findet auch eine Entzerrung der Kameradaten statt, um der Verzeichnung des eingesetzten Objektivs entgegenzuwirken.

Die Verzeichnung der Kamera wurde in Abschnitt 2.3.1 erläutert. Zur Kalibration wurden mit der Kamera Aufnahmen einer planen Platte mit einem schwarz-weißen Schachbrett-Muster aus verschiedenen Winkeln gemacht. Mit einer Kalibrationssoftware<sup>10</sup> konnte anschließend über die Detektion der einzelnen Felder die Verzerrung der Platte im Bild errechnet werden. Die bestimmten Parameter wurden anschließend zur Korrektur eingesetzt.

Um die entzerrten Daten der Kamera mit den Höhendaten des Laserscanners in der späteren Auswertung kombinieren zu können, muss eine zeitliche und räumliche Synchronisation erfolgen. Die zeitliche Synchronisation findet mit einem speziellen Synchronisationsobjekt statt, das von beiden Sensoren deutlich und genau zu detektieren ist. Konkret wurde ein weißer Hartkunststoffstreifen mit einer Höhe von 3 mm und einer Breite von 29 mm quer zur Laufrichtung des schwarzen Förderbands eingesetzt. Damit lässt sich sowohl auf dem 2D-Bild als auch im Höhenbild ein guter Kontrast erzielen (siehe Abb. 5.1).

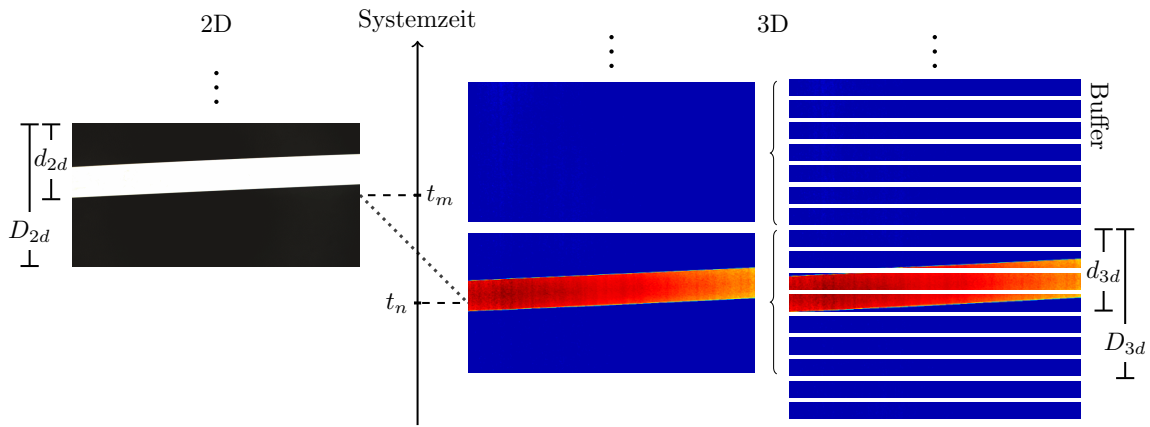


**Abbildung 5.1:** Ausschnitt aus dem Höhenprofil in Falschfarben (links) und dem Farbbild (rechts) des Synchronisationsobjekts

Zur automatischen zeitlichen Synchronisation wurde ein Algorithmus entwickelt, der die Farb- und Höhenübergänge und damit die Kanten des Streifens in beiden Messdaten findet. Dazu werden zuerst die Eckpunkte in beiden Datensätzen gesucht, wodurch eine gewisse Stabilität des Verfahrens gegenüber kleinen Rotationen

<sup>9</sup>Die Implementierung des kompletten Systems mit über 25.000 Codezeilen wurde in Zusammenarbeit mit weiteren Personen durchgeführt. Nach dem Autor dieser Arbeit waren insbesondere Patrick Peper [Pep17] und Heinz-Xaver Hesch [Hes15] an der Erstellung beteiligt.


<sup>10</sup>Camera Calibration Toolbox des California Institute of Technology



**Abbildung 5.2:** Verdeutlichung der zeitlichen Synchronisation. Die 3D-Werte sind in Falschfarben dargestellt.

des Streifens erreicht wird. Anschließend wird im 2D-Bild die Distanz des tiefsten Eckpunkts zur Bildkante  $d_{2d}$  ins Verhältnis zur Bildhöhe  $D_{2d}$  gesetzt und mit dem Verhältnis der Sensorauflösungen in die Größen  $D_{3d}$  bzw.  $d_{3d}$  umgerechnet. Damit können aus den einzelnen Messlinien des 3D-Sensors und dem zeitlichen Versatz  $\Delta t = t_m - t_n$  der Eckpunkte entsprechende Datenmatrizen zur Weiterverarbeitung erzeugt werden, die positionsmäßig exakt mit dem jeweiligen 2D-Bild übereinstimmen. Durch den Aufbau bedingt, kommen die Daten des Laserscanners zuerst im System an, weshalb sie in einem Buffer zwischengespeichert werden. Die Synchronisation erfolgt, sobald das Kalibrationsobjekt vollständig in beiden Daten enthalten ist. Abbildung 5.2 verdeutlicht den Zusammenhang.

Damit die beiden Sensordaten auch räumlich perfekt übereinander liegen, werden die Daten mit festgelegten Parametern zugeschnitten. Die Parameter wurden zuvor durch eine Kalibration bestimmt, bei der an den Förderbandrändern zwei weiße, runde Kalibrationsobjekte von beiden Sensoren vermessen wurden. Die jeweilige Position der Objektträger in den Daten wird anschließend zum Zuschnitt genutzt. Abbildung 5.3 veranschaulicht die linke Zuschnittsgrenze in den Sensordaten der Kamera (links) und des Laserscanners (rechts). Die Schnittgrenze ist jeweils in Form einer gestrichelten Linie eingezeichnet.



**Abbildung 5.3:** Veranschaulichung der räumlichen Synchronisation mittels Zuschnitt in 2D- und 3D-Daten. Die Höhenwerte sind in Falschfarben dargestellt (rechts).

Um die einzeln eintreffenden 3D-Linien anschließend mittels Bildverarbeitung weiterverarbeiten zu können, ist eine Zusammenfassung der Linien zu einer Matrix sehr

sinnvoll. Nach diesem Schritt werden die synchronisierten 2D- und 3D-Matrizen in die Segmentierung gegeben.

## 5.1.2 Segmentierung


Das Ziel der Segmentierung ist das Herausfiltern von Bauteildatensätzen aus den Messdaten. Dazu werden zuerst Messwerte identifiziert, die zu Bauteilen gehören könnten. Anschließend werden zusammenhängende Messwerte zu einem Bauteildatensatz zusammengefasst, der die Koordinaten und die entsprechenden Sensordaten enthält.

Bevor die Identifikation von Bauteilmesswerten erfolgen kann, müssen zuerst alle Datenpunkte extrahiert werden, die zu einer Leiterplatte gehören. Hierfür wird eine Filterung der Höhendaten mit einem Schwellwert durchgeführt und das Ergebnis in einem Binärbild gespeichert. Messdaten, deren Wert höher als dieser festgelegte Schwellwert ist, erzeugen in dem Binärbild logisch 1, alle anderen logisch 0. Anschließend wird die morphologische Operation „Schließen“ in Form einer Dilatation und einer Erosion angewandt, um durch Messrauschen oder fehlende Daten bedingte Löcher in den Leiterplattenpunkten zu schließen (siehe Abb. 5.4). Das optimierte Binärbild wird abschließend mit einem BLOB-Algorithmus auf zusammenhängende Punkte untersucht, die später als Leiterplatten interpretiert werden. Der zugehörige BLOB-Algorithmus ist in Abschnitt 2.3.3 beschrieben.

Im nächsten Schritt wird die Grundfläche der Leiterplatte identifiziert. Dazu wird die Annahme getroffen, dass diese eine plane Fläche ohne Verformungen bildet. Weiterhin wird angenommen, dass die Ebene einen gewissen Winkel zur Förderbandoberfläche einschließt, weil die meisten Leiterplatten aufgrund herausragender Komponenten nicht waagrecht auf der Förderbandoberfläche liegen. Basierend auf den Leiterplattendatenpunkten kann die Ebene anhand des RANSAC-Verfahrens identifiziert werden. Da die Annahme der Verformung insbesondere für große Leiterplatten nur bedingt stimmt, werden diese in Teilbereiche untergliedert, in denen Ebenen getrennt detektiert werden. Die Untergliederung erfolgt dabei automatisch, sobald die Leiterplatte einen gewissen Grenzwert überschreitet.




**Abbildung 5.4:** Veranschaulichung der BLOB-Detektion anhand einer Platine. Von links nach rechts: Selektierte Messwerte mittels Höhenschwellwert, anschließender Dilatation, Erosion und BLOB-Detektion.




**Abbildung 5.5:** Veranschaulichung des RANSAC-Ergebnisses in Form der Ebenenmesspunkte (links), Bauteilmesspunkte (mittig) und der damit erzielten Aufteilung (rechts). Die Höhenwerte der Messpunkte sind in Falschfarben dargestellt. Die Bauteilhöhen sind bereits um die Höhe der berechneten Platinenebene korrigiert. Diese liegt schief, weshalb die Höhenwerte links in einem Farbverlauf dargestellt sind.

Nachdem die Grundfläche identifiziert wurde, können die Messpunkte selektiert werden, die zu den Komponenten auf der Leiterplatte gehören. Punkte, die innerhalb eines gewissen Abstands zur gefundenen Ebene liegen, werden als Stützpunkte der Leiterplatte zugeordnet. Alle anderen Messpunkte werden als Bauteilmesspunkte betrachtet. Der Vorgang ist in Abbildung 5.5 dargestellt. Zur Optimierung der Selektion wird nun erneut mit einem Binärbild gearbeitet. Alle Messpunkte, die gemäß dem RANSAC-Ergebnis zu der Leiterplatte gehören, werden dabei auf logisch 0 gesetzt, die restlichen auf logisch 1. Messpunkte mit dem Wert logisch 1 werden nun den Komponenten zugeordnet.

Das erstellte Binärbild mit den Komponentendaten wird nun erneut mehreren morphologischen Operationen unterzogen. Diese werden durchgeführt, um das Messrauschen zu unterdrücken, zusammengewachsene Bauteile voneinander zu trennen und zusammengehörende Teile zusammenzufügen. Dazu kommen zuerst zwei modifizierte Erosion-Module nacheinander mit unterschiedlichen Parametern zum Einsatz. Diese verfügen gegenüber der konventionellen Variante neben der Größe  $\epsilon$  über einen weiteren Parameter in Form eines Schwellwerts  $\sigma$ . Dieser begrenzt bei der unter Abschnitt 2.3.2 beschriebenen Erosionsfaltung die maximale Anzahl an Bildpixeln mit dem Wert logisch 1 entsprechend dem Schwellwertanteil am Gesamtfenster. In der Praxis führt dies zu weniger Erosion. Die Begrenzung der Erosion ist für die nachfolgende Merkmalsextraktion wichtig, da hier auch die Form untersucht



**Abbildung 5.6:** Vergleich der konventionellen (mittig) mit der modifizierten Erosion (rechts) auf Basis der links dargestellten Eingangsdaten. Erodierete Werte sind rot hervorgehoben.



**Abbildung 5.7:** Darstellung der BLOB-Detektion für Bauteile. Von links nach rechts: Bauteilmessdaten original, nach Anwendung von Erosion und Dilatation, finale BLOB-Detektion. Einzelne BLOBs sind mit möglichst unterschiedlichen Farben veranschaulicht.

wird. Ein Vergleich mit dem konventionellen Erosion-Modul ist in Abbildung 5.6 dargestellt. Der Durchmesser des angewandten runden Erosionsoperators beträgt 7 Pixel, der Schwellwert für die modifizierte Erosion (rechts) 50 %. Die konventionelle Erosion (mittig) hat einen deutlich destruktiveren Einfluss als der modifizierte Operator (rechts). Im Anschluss an die Erosion wird eine Größenfilterung durchgeführt. Datenpunktgruppen, die dabei die Fenstergröße  $\gamma$  unterschreiten, werden gelöscht. Abschließend findet eine Dilatation der Größe  $\delta$  statt, um die Erosionseffekte zu minimieren.

Im Anschluss an die Morphologie wird erneut ein BLOB-Algorithmus zur Identifikation zusammenhängender Messwerte eingesetzt (Abbildung 5.7). Diese Messwertgruppen werden nun als potentielle Bauteile interpretiert und an die Merkmalsextraktion weitergereicht.

Um mit dem entwickelten Verfahren eine bestmögliche Segmentierung zu erzielen, ist es wichtig, die optimalen Parameter für die genannten morphologischen Operationen zu finden. Schlecht gewählte Parameter führen zum Zusammenwachsen von Bauteilsegmenten oder der unnötigen Erosion von Segmenten, was vor allem bei kleinen Bauteilen zur vollständigen Löschung führen kann. Zur Bestimmung der Parameter wurden deshalb über 120 Tests mit verschiedenen Konfigurationen durchgeführt. Die getesteten Parameter sind in Tabelle 5.1 aufgeführt. Zum Test wurde für jeden Parametersatz ein Teil aller Datensätze aus der unter Abschnitt 3 beschriebenen Datenbank durchgerechnet. Die Begrenzung auf einen Teil der Datenbank begründet sich aus der Laufzeit für einen kompletten Parametersatz. Die Laufzeit liegt bei Verwendung der vollständigen Datenbank bei etwa acht Stunden. Um sie zu begrenzen, wurde nur ein Drittel der Datenbank verwendet. Anschließend wurde automatisiert geprüft, wie groß die Anzahl  $N$  der positions- und größenmäßigen Übereinstimmungen zwischen den segmentierten Bauteilen und den Referenzdaten bzw. der GT ist. Als Übereinstimmung wurde festgelegt, dass die Bauteildatensätze zu mindestens 80 % mit der GT überlappen, die Überschneidungsfläche mindestens 40 % der GT betragen und das Verhältnis der gefilterten Größe zur GT-Größe zwischen 0,4 und 1,2 liegen muss. Damit darf das gefilterte Objekt minimal 40 % seiner tatsächlichen Größe betragen, um als positiv zu gelten. Dieser niedrige Schwellwert ist insbesondere den kleinen Bauteilen geschuldet, die durch die Morphologie verhältnismäßig

| Parameter                       | Werte                        | Beschreibung                            |
|---------------------------------|------------------------------|---|
| $\epsilon$ Erosion <sub>1</sub> | 0; 1; $\dots$ 4              | Durchmesser der kreisf. Erosion         |
| $\sigma$ Erosion <sub>1</sub>   | 0,2; 0,25; $\dots$ 0,45; 0,6 | Schwellwert zur Minimierung der Erosion |
| $\epsilon$ Erosion <sub>2</sub> | 0; 1; $\dots$ 4              | Durchmesser der kreisf. Erosion         |
| $\sigma$ Erosion <sub>2</sub>   | 0,2; 0,25; $\dots$ 0,45; 0,6 | Schwellwert zur Minimierung der Erosion |
| $\gamma$ Größenfilter           | 1; 3; $\dots$ 11; 4; 6       | Minimale quadratische Objektgröße       |
| $\delta$ Dilatation             | 1; 2; $\dots$ 4              | Durchmesser der kreisf. Dilatation      |

**Tabelle 5.1:** Untersuchte Morphologieparameter

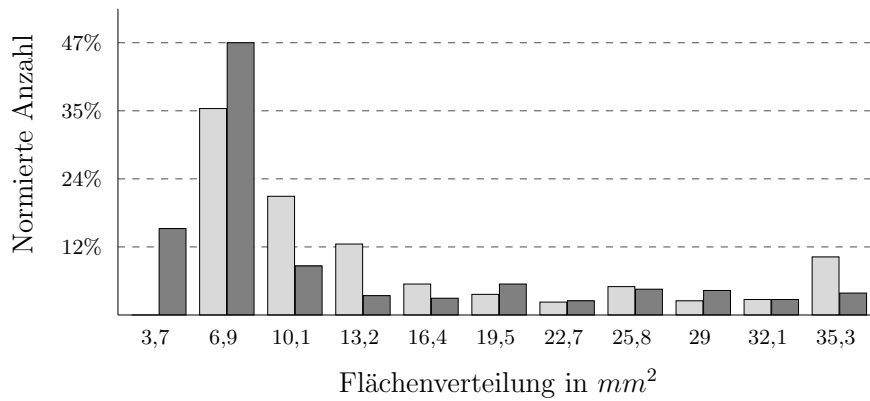
stark verkleinert werden. Weiterhin beeinflussen Störquellen wie Messrauschen und Verdeckungen die Größen und Formen der segmentierten Bauteile. Ein Vergleich der Referenzgrößen mit den berechneten Größen aus der Segmentierung ist in Form eines Diagramms in Abbildung 5.8 für Tantalkondensatoren dargestellt. Aus dem Diagramm lässt sich entnehmen, dass segmentierte Tantalkondensatoren im Vergleich zur Markierung in der Datenbank regelmäßig kleiner erschienen. Die fünf besten Parametersätze mit den höchsten Gesamtübereinstimmungen  $N$  sind in Tabelle 5.2 dargestellt. „Ta. schw.“ steht hier für schwarze Tantalkondensatoren.

| # | $\epsilon_1$ | $\sigma_1$ | $\epsilon_2$ | $\sigma_2$ | $\gamma$ | $\delta$ | $N$   | IC    | Elko  | Ta. schw. |
|---|--------------|------------|--------------|------------|----------|----------|-------|-------|-------|-----------|
| 1 | 1            | 0,35       | 1            | 0,6        | 4        | 1        | 83,07 | 91,10 | 89,70 | 84,50     |
| 2 | 2            | 0,2        | 1            | 0,6        | 4        | 1        | 82,82 | 91,47 | 90,13 | 83,21     |
| 3 | 3            | 0,2        | 1            | 0,6        | 4        | 1        | 82,55 | 88,70 | 89,58 | 82,08     |
| 4 | 2            | 0,3        | 1            | 0,6        | 1        | 1        | 81,77 | 92,19 | 91,35 | 82,32     |
| 5 | 2            | 0,3        | 1            | 0,6        | 3        | 1        | 81,73 | 92,19 | 91,35 | 82,49     |

**Tabelle 5.2:** Prozentzahl der positions- und größenmäßigen Übereinstimmungen zwischen den segmentierten Bauteilen und den Referenzdaten für unterschiedliche Klassen und Parametersätze

### 5.1.3 Merkmalerstellung und untersuchte Merkmale

Der Teilbereich Merkmalerstellung bereitet aus den Bauteildatensätzen Merkmalsvektoren vor, die in der nachfolgenden Klassifikation in die entsprechenden Klassen eingeteilt werden. Um eine möglichst hohe Erkennungsrate zu erreichen, wurden im Rahmen der Arbeit verschiedene Merkmale getestet. Zum Testen wurden alle Merkmale, jeweils mit verschiedenen Parametern, auf Basis der vorsegmentierten Objekte berechnet und zur Vergleichbarkeit mit dem gleichen RF klassifiziert. Der RF wurde dabei immer mit den selben Einstellungen betrieben. Diese sind im nächsten Abschnitt in Tabelle 5.9 erläutert. Weiterhin wurde die Menge der in der Datenbank vorhandenen Klassen auf eine Untermenge reduziert, die die wichtigsten Komponenten abdeckt. Diese wurde ebenfalls genutzt, um die im folgenden Kapitel be-



**Abbildung 5.8:** Histogramm der in der Datenbank hinterlegten (hellgrau) und segmentierten Flächen (dunkelgrau) von gelben Tantalkondensatoren.

schriebenen Tests der Merkmalsvektoren durchzuführen. Die Zusammensetzung der Untermenge ist in Tabelle 5.3 beschrieben. Eine Aufzählung der getesteten Merkmale ist in Tabelle 5.4 dargestellt. Nachfolgend sind alle Verfahren zusammen mit den getesteten Parametern beschrieben. Die Erkennungsraten werden zum Schluss vergleichend erläutert. Die in diesem Abschnitt beschriebenen Resultate sind teilweise auch in vorangegangenen Veröffentlichungen enthalten bzw. bauen darauf auf [Rue+16c], [Rue+17a], [Rue+17b].

Um die optimale Ausnutzung der kombinierten Messdaten sicherzustellen, wurde ein eigenes Merkmal erstellt. Es handelt sich dabei um einen Merkmalsvektor, der aus 15 verschiedenen geometrischen, farblichen und statistischen Kenngrößen (GFSK) besteht. Alle Kenngrößen sind vergleichsweise schnell zu berechnen, was sich auf die Laufzeit positiv auswirkt. Eine Übersicht ist in Tabelle 5.5 aufgeführt. Zur Berechnung der Form und der Formpassung wird angenommen, dass die Orientierung der Leiterplatte bzw. der Bauteile  $0^\circ$ ,  $90^\circ$ ,  $180^\circ$  oder  $270^\circ$  zur Vorzugsrichtung des Förderbands beträgt. Eine Abweichung von diesen Orientierungen führt daher konzeptbedingt zu einer Verschlechterung der Merkmale. Abweichungen von bis  $\pm 10^\circ$  zeigen jedoch nur sehr geringe Auswirkungen.

| Zuordnungen Untermenge $\leftarrow$ Datenbank-Klasse |              |                |          |              |          |          |              |              |
|--|--------------|----------------|----------|--------------|----------|----------|--------------|--------------|
| Tantal   | $\leftarrow$ | Tantal gelb    | Quarz    | $\leftarrow$ | Quarz    | Unklass. | $\leftarrow$ | Kühler       |
| Tantal   | $\leftarrow$ | Tantal orange  | Unklass. | $\leftarrow$ | Unklass. | Unklass. | $\leftarrow$ | Batterie     |
| Tantal   | $\leftarrow$ | Tantal schwarz | Unklass. | $\leftarrow$ | Stecker  | Unklass. | $\leftarrow$ | Batt.-Sockel |
| IC   | $\leftarrow$ | IC             | Unklass. | $\leftarrow$ | Pins     | Unklass. | $\leftarrow$ | CPU          |
| IC   | $\leftarrow$ | asym. IC       | Unklass. | $\leftarrow$ | Buchse   | Unklass. | $\leftarrow$ | CPU-Sockel   |
| IC   | $\leftarrow$ | BGA            | Unklass. | $\leftarrow$ | Spule    |          |              |              |
| Elko   | $\leftarrow$ | Elko           | Unklass. | $\leftarrow$ | Trafo    |          |              |              |

**Tabelle 5.3:** Zusammensetzung der reduzierten Untermenge

| Merkmalsname       | Sensor | Beschreibung                  |
|--------------------|--------|-------------------------------|
| GFSK               | 2D, 3D | div. Messgrößen (Höhe, Farbe) |
| HOG                | 2D     | siehe Abschn. 2.4             |
| LBP                | 2D     | siehe Abschn. 2.4             |
| Rohdaten + PCA     | 2D, 3D | Rohdaten, PCA                 |
| Spektrometer + PCA | 2D     | Spektr. Messungen, PCA        |


**Tabelle 5.4:** Getestete Merkmale

Die Aussagekraft der einzelnen Werte wurde mit der in Abschnitt 2.5.5 vorgestellten Entropieänderung  $\Delta H$  ermittelt. Die höchste Aussagekraft bzw. Trennschärfe besitzt die Bauteilhöhe. Das ist insofern verständlich, als dass die untersuchten Bauteile innerhalb der Klassen meist ähnliche Höhen aufweisen. Bauteile unterschiedlicher Klassenangehörigkeit unterscheiden sich jedoch meist deutlich in der Höhe. Die geringste Aussagekraft im Vektor bietet die Form-Einteilung in Rechteck oder Kreis, was darauf zurückzuführen ist, dass über 85 % der Bauteile besser von einem Rechteck approximiert werden.

Neben der Untersuchung des GFSK wurde auch das in Abschnitt 2.4 beschriebene HOG- sowie das LBP-Verfahren als Merkmal geprüft. Um diese Verfahren testen zu können, müssen die aus den segmentierten Objekten gewonnenen Daten zuerst auf eine feststehende normierte Größe skaliert werden, woraus eine gleichbleibende Länge des Merkmalsvektors resultiert. Die Festsetzung einer gleichbleibenden Länge ist nötig, um den Merkmalsvektor im Anschluss klassifizieren zu können. Aufgrund

| Merkmalsname           | $\Delta H$ | Beschreibung                              |
|------------------------|------------|---|
| Höhe                   | 0,815      | Durchschnittliche Höhe in mm              |
| $\sigma_{\text{Höhe}}$ | 0,318      | Standardabweichung Höhe                   |
| Form                   | 0,184      | Unterteilt in Rechteck oder Kreis         |
| Formpassung            | 0,262      | Prozentuale Übereinstimmung mit der Form  |
| Oberfläche             | 0,573      | Größe der Oberfläche in Pixel             |
| Kleinste Achse         | 0,52       | Länge der kleinsten Bauteilachse          |
| Größte Achse           | 0,624      | Länge der größten Bauteilachse            |
| Exzentrizität          | 0,491      | Exzentrizität des Bauteils                |
| Umfang                 | 0,592      | Größe der begrenzenden Umrandung in Pixel |
| Rot                    | 0,711      | Durchschnittswert des roten Farbkanals    |
| $\sigma_{\text{Rot}}$  | 0,52       | Standardabweichung Rot                    |
| Grün                   | 0,727      | Durchschnittswert des grünen Farbkanals   |
| $\sigma_{\text{Grün}}$ | 0,51       | Standardabweichung Grün                   |
| Blau                   | 0,724      | Durchschnittswert des blauen Farbkanals   |
| $\sigma_{\text{Blau}}$ | 0,568      | Standardabweichung Blau                   |

**Tabelle 5.5:** Zusammensetzung des GFSK-Merkmalsvektors



**Abbildung 5.9:** Darstellung der prozentualen Vergrößerung zur zusätzlichen Erfassung von Umgebungsdaten. Die aus dem BLOB-Algorithmus stammende Segmentierung ist für einen IC (links) im zugehörigen 2D-Bereich rot gekennzeichnet (mittig). Der zu extrahierende Bildbereich ist für zwei unterschiedliche Vergrößerungen mit einer weißen Umrandung gekennzeichnet (rechts).

der Größenverteilung der untersuchten Bauteile (siehe Abb. 5.8) ist die Skalierung jedoch als problematisch anzusehen, weil dadurch möglicherweise relevante Informationen verloren gehen. Natürlich ist auch die zuvor berechnete Segmentierung als potentielle Fehlerquelle anzusehen, da die hieraus resultierenden Segmente im Vergleich mit den originalen Bauteilen meist zu klein sind. Deshalb wurde für alle Verfahren eine zusätzliche, prozentuale Segmentvergrößerung einbezogen, was neben der Korrekturmöglichkeit auch das Miteinbeziehen der unmittelbaren Umgebungsdaten sicherstellt. Abbildung 5.9 veranschaulicht dieses Vorgehen für einen IC. Auf IC-Objekten basierende Segmente decken häufig nur den unmittelbaren Bereich des schwarzen Gehäuses ab. Das daraus resultierende Datenfenster umfasst deshalb die Kontakte meist nicht. Mittels einer prozentualen Vergrößerung können sie dennoch in den Algorithmen miteinbezogen werden.

Darüber hinaus wurden auch die Rohdaten als potentieller Merkmalsvektor getestet. Diese wurden dazu ebenfalls, wie beschrieben, auf eine normierte Größe skaliert. Die daraus resultierenden Datenmengen sind jedoch bei relativ kleinen Fenstergrößen bereits sehr groß. So ergibt sich aus einer Fenstergröße von 32 x 32 Pixeln bei drei Farbkanälen und zusätzlichen Höhenwerten bereits ein Vektor von 4096 einzelnen Einträgen. Um die Datenmengen auf das Wesentliche zu reduzieren, wurde eine PCA durchgeführt und in der Folge nur die wichtigsten Hauptkomponenten zur Merkmalsberechnung eingesetzt.

Nicht ganz vergleichbar mit den restlichen Merkmalen ist die Untersuchung spektraler Datensätze im sichtbaren und Nah-Infrarot-Bereich, die als Merkmalsvektor getestet wurden. Die dazu nötigen Rohdaten wurden mit der in Abschnitt 4.4 beschriebenen Spektroskopiehalbkugel aufgenommen. Diese ist nicht an die Detektionsanlage angeschlossen, weshalb die Messwerte auch nicht mittels der erläuterten Vorverarbeitung und Segmentierung extrahiert werden konnten. Stattdessen wurden einzelne Leiterplatten mit dem beschriebenen Aufbau vermessen, die zu testenden

| Verfahren   | Parameter     | Werte                | Bedeutung                         |
|-------------|---------------|----------------------|-----------------------------------|
| HOG         | Fenstergröße  | 32x32; <b>64x64</b>  | Größe des Eingangsbildes          |
| HOG         | Verbreiterung | 0,1; <b>0,2</b>      | Prozentuale Fenstervergrößerung   |
| HOG         | Zellengröße   | 4; 8; <b>16</b>      | Seitenlänge der quadr. HOG-Zellen |
| HOG         | #Bins         | 9; <b>18</b>         | Anzahl der Histogrammbalken       |
| HOG         | neg. Winkel   | <b>ja</b> ; nein     | Begrenzung der Winkel auf 0-180°  |
| LBP         | Fenstergröße  | 32x32; <b>64x64</b>  | Größe des Eingangsbildes          |
| LBP         | Verbreiterung | <b>0,05</b>          | Prozentuale Fenstervergrößerung   |
| LBP         | Zellengröße   | 32; <b>64</b>        | Seitenlänge der quadr. LBP-Zellen |
| LBP         | #Nachbarn     | 4; <b>8</b>          | Verglichene Nachbarpixel          |
| LBP         | Radius        | <b>1</b> ; 3; 5      | Distanz der untersuchten Nachbarn |
| LBP         | rotationsinv. | <b>ja</b> ; nein     | Rotationsinvariante Berechnung    |
| 2D,3D,PCA   | Fenstergröße  | <b>32x32</b> ; 64x64 | Größe des Eingangsbildes          |
| 2D,3D,PCA   | Verbreiterung | <b>0,05</b> ; 0,1    | Prozentuale Fenstervergrößerung   |
| 2D,3D,PCA   | #Komponenten  | 5; 10; 20; <b>40</b> | Anzahl an PCA-Vektoren            |
| 2D,3D,PCA   | zentriert     | <b>ja</b> ; nein     | Verschiebung auf den Nullpunkt    |
| Spekt., PCA | #Komponenten  | 5; 10; 20; <b>40</b> | Anzahl an PCA-Vektoren            |

**Tabelle 5.6:** Variierte Parameter bei der Untersuchung verschiedener Merkmale

Bauteile in den Datensätzen manuell markiert und die Werte für die einzelnen Spektralkanäle für jedes Bauteil gemittelt. Der so gewonnene Spektroskopiedatenvektor besteht aus 210 Einträgen, die jeweils mit der Messung eines bestimmten Wellenlängenbereichs bei einem definierten Einfallswinkel korrespondieren. Zum Einsatz als Merkmalsvektor wurde eine Reduzierung mittels PCA auf 5 bis 40 Dimensionen durchgeführt.

Aufgrund des erhöhten Aufwands wurden nur neun große Leiterplatten aus dem verfügbaren Elektroschrott ausgewählt und untersucht. Insgesamt sind 1009 Datensätze einzelner Komponenten enthalten, also etwa um den Faktor 10 weniger als in der sonst verwendeten Datenbank. Damit sind die Werte der in Tabelle 5.8 aufgeführten Klassifikationen nicht ganz so aussagekräftig und nur hinsichtlich der Tendenz mit den anderen Ergebnissen vergleichbar.

Um möglichst hohe Erkennungsraten für die beschriebenen Verfahren zu erreichen, wurde für jedes Verfahren neben den individuellen Parametern wie Blockgrößen und Anzahl an untersuchten Nachbarn auch die Eingangsdatengröße variiert. Je nach Parametrierung ändert sich dabei die Länge des berechneten Merkmalsvektors. Beispielsweise bestimmt die Anzahl der eingesetzten Hauptkomponenten im PCA-Rohdaten-Verfahren direkt die Länge des Resultats. Längere Ausgangsvektoren stellen meist etwas mehr Informationen zur Verfügung, was sich in einer höheren Klassifikationsrate äußern kann. Negativ ist jedoch der nötige Berechnungsaufwand in der Erzeugung wie auch in der Klassifikation zu sehen. Die geprüften Parameter der drei Verfahren sind in Tabelle 5.6 dargestellt, wobei die Parameter mit der höchsten Detektionsrate hervorgehoben sind. Insgesamt wurden durch die unter-

| Verfahren                 | Rate    | Länge |
|---------------------------|---------|-------|
| GFSK                      | 94,34 % | 15    |
| Spekt., PCA               | 86,59 % | 40    |
| LBP                       | 82,47 % | 236   |
| HOG                       | 82,44 % | 324   |
| 2D, 3D, PCA               | 80,53 % | 40    |
| GFSK + LBP <sub>10</sub>  | 94,77 % | 25    |
| GFSK + LBP <sub>236</sub> | 90,67 % | 251   |

**Tabelle 5.7:** Gesamterkennungsraten der getesteten Merkmale mit den besten Parametersätzen

schiedlichen Parametersets über 100 verschiedene Merkmalsberechnungen basierend auf der vollständigen Datenbank durchgeführt und die Resultate klassifiziert.

Die Erkennungsraten sind für alle getesteten Verfahren mit den jeweils besten Parametern in Tabelle 5.7 enthalten. Neben den beschriebenen Verfahren sind auch zwei Kombinationen von LBP-Daten unterschiedlicher Länge mit dem entwickelten GFSK zum Vergleich angegeben. Weiterhin enthält die Tabelle auch die jeweilige Länge des Merkmalsvektors. Die entsprechenden Wahrheitsmatrizen sind in Tabelle 5.8 kombiniert dargestellt.

Insgesamt ist ersichtlich, dass die RF-Klassifikation des GFSK-Merkmals für den vorgestellten Klassenmix gegenüber den restlichen Verfahren am besten funktioniert und darüber hinaus die kürzeste Vektorlänge besitzt. Eine Kombination mit dem besten LBP-Ergebnis, das 236 Einträge besitzt, verschlechtert das Resultat um etwa 4 % (GFSK + LBP<sub>236</sub>). Dies liegt vermutlich daran, dass Einträge mit hoher Informationsdichte durch die vielen Merkmale mit geringerer Information aus dem LBP nicht mehr mit der gleichen Gewichtung in den RF eingehen. Bei Verwendung eines kürzeren LBP-Resultats mit nur zehn Einträgen und einer einzelnen Erkennungsrate von 80,33 % steigt das Gesamtergebnis hingegen um 0,43 % auf 94,77 % (GFSK + LBP<sub>10</sub>). Die vergleichsweise aufwendige Berechnung des LBPs steht jedoch im Hinblick auf die Echtzeitfähigkeit nicht in Relation zu der geringen Verbesserung, weshalb in der finalen Software-Version nur der GFSK-Merkmalvektor zum Einsatz kommt.

Das beste HOG-Resultat liefern Parameter, die zu einer Merkmalslänge von 324 Einträgen führen. Verglichen mit dem GFSK fallen insbesondere bei der Wahrheitsmatrix große Abweichungen auf. Während bei Verwendung des GFSKs beispielsweise 483 Tantalkondensatoren korrekt klassifiziert wurden, sind es im Fall des HOGs nur noch 298 richtige Klassifikationen. Beim Vergleich des HOGs mit den LBP-Daten fällt auf, dass bei Verwendung des HOGs Tantalkondensatoren und ICs untereinander wesentlich besser unterschieden werden können. Dafür ist die Verwechslungsrate mit den Komponenten in „Unklassifiziert“ etwa doppelt so hoch wie im Falle des

| GFSK     |          |          |          |          | GFSK + LBP <sub>10</sub> |          |          |          |          |                            |
|----------|----------|----------|----------|----------|--------------------------|----------|----------|----------|----------|----------------------------|
| <b>a</b> | <b>b</b> | <b>c</b> | <b>d</b> | <b>e</b> | <b>a</b>                 | <b>b</b> | <b>c</b> | <b>d</b> | <b>e</b> | ← klassifiziert als        |
| 483      | 11       | 0        | 0        | 10       | 480                      | 12       | 0        | 0        | 12       | <b>a = Tantal</b>          |
| 15       | 1171     | 4        | 0        | 35       | 11                       | 1178     | 4        | 0        | 32       | <b>b = IC</b>              |
| 0        | 3        | 498      | 0        | 9        | 0                        | 3        | 498      | 0        | 9        | <b>c = Elko</b>            |
| 6        | 1        | 0        | 50       | 17       | 6                        | 1        | 0        | 52       | 15       | <b>d = Quarz</b>           |
| 21       | 43       | 10       | 11       | 1064     | 22                       | 39       | 9        | 6        | 1073     | <b>e = Unklassifiziert</b> |

| HOG      |          |          |          |          | LBP      |          |          |          |          |                            |
|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------------------------|
| <b>a</b> | <b>b</b> | <b>c</b> | <b>d</b> | <b>e</b> | <b>a</b> | <b>b</b> | <b>c</b> | <b>d</b> | <b>e</b> | ← klassifiziert als        |
| 298      | 63       | 4        | 0        | 139      | 331      | 100      | 0        | 0        | 73       | <b>a = Tantal</b>          |
| 4        | 1103     | 4        | 0        | 114      | 32       | 1117     | 4        | 0        | 72       | <b>b = IC</b>              |
| 1        | 5        | 462      | 0        | 42       | 5        | 6        | 447      | 0        | 52       | <b>c = Elko</b>            |
| 0        | 3        | 6        | 13       | 52       | 1        | 4        | 0        | 17       | 52       | <b>d = Quarz</b>           |
| 18       | 129      | 24       | 0        | 978      | 47       | 134      | 25       | 0        | 943      | <b>e = Unklassifiziert</b> |

| 2D, 3D, PCA |          |          |          |          | Spekt., PCA |          |          |          |          |                            |
|-------------|----------|----------|----------|----------|-------------|----------|----------|----------|----------|----------------------------|
| <b>a</b>    | <b>b</b> | <b>c</b> | <b>d</b> | <b>e</b> | <b>a</b>    | <b>b</b> | <b>c</b> | <b>d</b> | <b>e</b> | ← klassifiziert als        |
| 249         | 163      | 1        | 0        | 91       | 63          | 0        | 0        | 0        | 0        | <b>a = Tantal</b>          |
| 18          | 1118     | 7        | 0        | 82       | 0           | 71       | 2        | 0        | 8        | <b>b = IC</b>              |
| 0           | 3        | 459      | 0        | 48       | 0           | 2        | 63       | 0        | 8        | <b>c = Elko</b>            |
| 6           | 4        | 0        | 2        | 62       | 0           | 1        | 5        | 1        | 3        | <b>d = Quarz</b>           |
| 24          | 139      | 25       | 1        | 960      | 0           | 16       | 1        | 0        | 99       | <b>e = Unklassifiziert</b> |

**Tabelle 5.8:** Wahrheitsmatrizen getesteter Merkmale mit den besten Parametern

LBP. Kanteninformationen bieten demnach gegenüber Farbinformationen für bestimmte Fälle Vorteile bei der Bauteilklassifikation. Reine Farb- und Höhenwerte in Kombination mit PCA sind jedoch nicht gut geeignet, um Bauteile zu klassifizieren. Insbesondere fällt die hohe Fehlerrate bei Tantal-Kondensatoren und Quarzen auf, wodurch diese Art von Merkmal zur Bauteilklassifikation disqualifiziert wird.

Neben dem GFSK-Merkmal erscheinen die Spektroskopiedaten besonders gut geeignet zu sein. So fällt die geringe Fehl-Erkennungsrate für ICs, Elkos und das optimale Resultat für Tantal-Kondensatoren auf. Auf Basis dieser Auswertung wurden von Katja Heymann vom Leibniz-Institut für Oberflächenmodifizierung e.V. weitere Messungen im NIR-Bereich durchgeführt, die jedoch negative Resultate erbrachten. Weitere Tests sind deshalb nötig, um Spektroskopiedaten für Bauteile im NIR- bzw. VIS-Bereich zu evaluieren.

#### 5.1.4 Klassifizierung

Der letzte Teilbereich in der Software übernimmt die Klassifizierung der Merkmalsvektoren. Dieser Bereich prädiziert die Klassenzugehörigkeit für jeden Merkmalsvek-


| Klassifikator | Parameter   | Wert       | Erläuterung                       |
|---------------|-------------|------------|-----------------------------------|
| RF            | #Bäume      | 1000       | Anzahl der eingesetzten Bäume     |
| RF            | #Merkmale   | alle       | Anzahl möglicher Merkmale je Baum |
| SVM           | Art         | 1-vs-1     | Art der eingesetzten SVM          |
| SVM           | Kernel      | Polynomial | Polynomialkernel Grad 2           |
| KNN           | Architektur | 15-8-8-4-5 | Anzahl der Knoten je Schicht      |
| KNN           | Lernrate    | 0,3        | Lernrate für Gewichtsänderungen   |
| KNN           | Momentum    | 0,2        | Gewicht beim Training             |
| KNN           | #Durchläufe | 500        | Anzahl an Trainingsläufen         |

**Tabelle 5.9:** Parametrierungen der getesteten Klassifikatoren. Die verwendeten CNN-Parameter sind in Abb. 5.10 dargestellt.


tor. Zur Durchführung der Evaluation der Klassifikatoren kommt das im letzten Abschnitt in Tabelle 5.5 beschriebene GFSK-Merkmal zum Einsatz. Getestet wurden drei klassische Klassifikatoren (RF, SVM, KNN) und ein neuartiger Ansatz in Form eines CNN. Die wichtigsten verwendeten Parameter sind in Tabelle 5.9 notiert und entsprechen einer einfachen Konfiguration. Die damit berechneten Wahrheitsmatrizen bzw. Erkennungsraten sind in Tabelle 5.10 bzw. 5.11 aufgeführt. Sie wurden, abgesehen von den Resultaten für das CNN, wie auch die Resultate aus den Merkmalstests, unter Verwendung der Software WEKA der Universität von Waikato, Neuseeland, erzeugt. Dabei handelt es sich um eine Plattform für maschinelles Lernen [Wit+16]. Die entworfene CNN-Architektur ist einschließlich der verwendeten Parameter in Abbildung 5.10 dargestellt und wurde mit MATLAB getestet.

Um zum Training genügend Daten zur Verfügung zu haben, wurde das CNN mit der kompletten Datenbank trainiert. Getestet wurde anschließend mit älteren Leiterplattenaufnahmen, die nicht in der Datenbank enthalten waren. Die daraus erhaltenen Klassifikationen wurden anschließend manuell optisch überprüft, wobei eine Klassifikation als positiv gewertet wurde, falls das bewertete Suchfenster ein Bauteil der entsprechenden Klasse zu mehr als 50 % abdeckte. Eine beispielhafte Klassifikation ist in Abb. 5.11 dargestellt.

Beim Vergleich der erzielten Resultate zeigt sich, dass der RF die beste Klassifikation liefert, was sich sowohl in der Gesamtdetektionsrate als auch in den Werten für  $\kappa$  und ROC-AUC niederschlägt. Verglichen mit der SVM werden die Tantalkondensatoren und Quarze wesentlich besser eingeordnet. Auch im Vergleich mit dem



**Abbildung 5.10:** Architektur des entwickelten CNNs entnommen aus [Rue+17b]



**Abbildung 5.11:** Klassifikationsergebnis des CNN für eine Testplatte. Die eingezeichneten Klassifikationen wurden durch das CNN mit mehr als 95 % Wahrscheinlichkeit klassifiziert.

| Klassifikator | Gesamtdetektionsrate | $\kappa$ | ROC-AUC | Tantal |
|---------------|----------------------|----------|---------|--------|
| RF            | 94,34 %              | 0,92     | 0,996   |        |
| KNN           | 87,20 %              | 0,82     | 0,977   |        |
| SVM           | 86,28 %              | 0,81     | 0,953   |        |
| CNN           | -                    | -        | -       | -      |

**Tabelle 5.10:** Ausgewertete Kenngrößen zur Bewertung der Klassifikatoren

KNN ergibt sich ein ähnliches Bild. Beim KNN fällt auf, dass sehr viele Tantal-kondensatoren als ICs erkannt werden, während die restlichen Werte durchaus mit dem Resultat des RF vergleichbar sind. Die CNN-Ergebnisse sind aufgrund der unterschiedlichen Datenbasis nicht unmittelbar vergleichbar, jedoch im Rahmen eines ersten Ansatzes als akzeptabel zu bezeichnen. Im aufgeführten Beispielbild (Abb. 5.11) ist insbesondere die Tantal-Detektion positiv hervorzuheben. Bei den klassifizierten ICs sind dagegen viele Fehlklassifikationen auffällig. Weiterhin hat sich die lange Dauer der CNN-Klassifikationen im Bereich einiger Minuten in der Praxis als problematisch erwiesen. Die lange Prozessierungsdauer geht unter anderem darauf zurück, dass der in Abschnitt 2.5.4 erwähnte Algorithmus zur Regionsselektierung für Leiterplatten nur suboptimal funktioniert. Der Grund liegt vermutlich in den stark heterogenen Bilddaten, die viele Muster erkennen lassen. Als Ersatz wurden im Rahmen einer erschöpfenden Suche mögliche Regionsvorschläge in verschiedenen Größenabstufungen aus den Bilddaten extrahiert. Deshalb mussten je Bild bis zu  $10^6$  einzelne Regionen von dem CNN beurteilt werden. Dadurch übersteigt die Menge der „Unklassifiziert“-Komponenten  $10^7$ , weshalb sie in der Tabelle mit X gekennzeichnet wird.

| RF       |          |          |          |          | SVM      |          |          |          |          |                            |
|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------------------------|
| <b>a</b> | <b>b</b> | <b>c</b> | <b>d</b> | <b>e</b> | <b>a</b> | <b>b</b> | <b>c</b> | <b>d</b> | <b>e</b> | ← klassifiziert als        |
| 483      | 11       | 0        | 0        | 10       | 447      | 32       | 0        | 0        | 25       | <b>a = Tantal</b>          |
| 15       | 1171     | 4        | 0        | 35       | 77       | 1105     | 4        | 0        | 39       | <b>b = IC</b>              |
| 0        | 3        | 498      | 0        | 9        | 1        | 3        | 492      | 0        | 14       | <b>c = Elko</b>            |
| 6        | 1        | 0        | 50       | 17       | 5        | 1        | 0        | 0        | 68       | <b>d = Quarz</b>           |
| 21       | 43       | 10       | 11       | 1064     | 91       | 92       | 23       | 0        | 943      | <b>e = Unklassifiziert</b> |
| KNN      |          |          |          |          | CNN*     |          |          |          |          |                            |
| <b>a</b> | <b>b</b> | <b>c</b> | <b>d</b> | <b>e</b> | <b>a</b> | <b>b</b> | <b>c</b> | <b>d</b> | <b>e</b> | ← klassifiziert als        |
| 339      | 152      | 0        | 0        | 13       | 12       | 3        | 0        | 0        | 17       | <b>a = Tantal</b>          |
| 1        | 1170     | 4        | 0        | 50       | 1        | 500      | 3        | 1        | 22       | <b>b = IC</b>              |
| 0        | 3        | 490      | 0        | 17       | 0        | 1        | 291      | 0        | 42       | <b>c = Elko</b>            |
| 2        | 4        | 0        | 42       | 26       | 0        | 1        | 1        | 17       | 4        | <b>d = Quarz</b>           |
| 22       | 87       | 26       | 36       | 978      | 36       | 173      | 55       | 15       | X        | <b>e = Unklassifiziert</b> |

**Tabelle 5.11:** Wahrheitsmatrizen verschiedener Klassifikatoren (\*aus [Rue+17b])

## 5.1.5 Erweiterung der Datenbank um künstliche Daten

Die zum Test verwendete Datenbank weist erhebliche Ungleichheiten hinsichtlich der Klassenanzahl der einzelnen Klassen auf. Auch in der angepassten Auswahl übersteigt das Verhältnis der größten Klasse zur kleinsten Klasse 10 zu 1 (siehe Tabelle 5.12). Durch dieses Missverhältnis kann es zu negativen Effekten beim Training von Klassifikatoren kommen. Eine Möglichkeit zum Beheben dieses Missverhältnisses ist das Erzeugen künstlicher Daten für das Training. Dazu kann der von [Cha+02] entwickelte Algorithmus zur synthetischen Datenerzeugung mittels Überabtastung zum Einsatz kommen (engl. synthetic minority over-sampling technique, SMOTE). Beim SMOTE-Verfahren wird für die Erzeugung eines neuen Merkmals  $\mathbf{m}_n$  zuerst ein altes Merkmal  $\mathbf{m}_a$  der unterrepräsentierten Klasse ausgewählt. Für dieses Merkmal werden im nächsten Schritt die  $k$  nächsten Nachbarn bestimmt. Aus dieser Menge wird dann ein Nachbarmerkmal  $\mathbf{m}_b$  zufällig ausgewählt. Anschließend wird für jedes Attribut  $i$  des Merkmalsvektors der Unterschied  $d_i$  zwischen den ausgewählten Merkmalen berechnet (Gl. 5.1). Zur Berechnung des neuen Merkmals  $\mathbf{m}_n$  wird dieser Unterschied für jedes Attribut berechnet, auf das ausgewählte Merkmal  $\mathbf{m}_a$  aufaddiert und mit einem zufälligen Faktor  $x$  multipliziert (Gl. 5.2). [Cha+02]

$$d_i = m_{a,i} - m_{b,i} \quad (5.1)$$

$$m_{n,i} = m_{a,i} + d_i \cdot x, \quad 0 \leq x \leq 1 \quad (5.2)$$

Mittels SMOTE wurde die Anzahl der in der Datenbank enthaltenen Instanzen auf 10000 Instanzen je Klasse erhöht und zum Training eines RF verwendet. Um beim nachfolgenden Test auf originale Daten zugreifen zu können, wurde zuvor ein Drittel der Daten aus der originalen Datenbank entfernt. Die Resultate für dieses Verfahren sind in Tabelle 5.13 aufgeführt. Insgesamt konnte die Klassifikationsrate auf 95,5 % angehoben werden, was in etwa einer Steigerung um 1 % gegenüber der unveränderten Datenbank entspricht. Vor dem Hintergrund der bereits sehr guten Detektionsrate kann diese Steigerung als durchaus relevant betrachtet werden.

| Klasse          | Anzahl |
|-----------------|--------|
| Tantal          | 1555   |
| IC              | 3584   |
| Elko            | 1472   |
| Quarz           | 234    |
| Unklassifiziert | 3337   |
| Gesamt          | 10182  |

**Tabelle 5.12:** Anzahl der Instanzen pro Klasse

| RF + SMOTE |          |          |          |          |                            |
|------------|----------|----------|----------|----------|----------------------------|
| <b>a</b>   | <b>b</b> | <b>c</b> | <b>d</b> | <b>e</b> | ← klassifiziert als        |
| 511        | 3        | 0        | 2        | 19       | <b>a = Tantal</b>          |
| 9          | 1139     | 2        | 2        | 29       | <b>b = IC</b>              |
| 0          | 3        | 516      | 0        | 6        | <b>c = Elko</b>            |
| 0          | 0        | 0        | 67       | 6        | <b>d = Quarz</b>           |
| 22         | 23       | 10       | 19       | 1074     | <b>e = Unklassifiziert</b> |

**Tabelle 5.13:** Wahrheitsmatrix des RF in Kombination mit durch SMOTE erweiterten Trainingsdaten

## 5.2 Evaluation der Echtzeitfähigkeit

Um eine möglichst rasche Berechnung der Ergebnisse durch die beschriebene Software zu ermöglichen, wurde sie in einzelne Module bzw. Threads aufgeteilt. Jedes Modul dient einer gewissen Aufgabe und kann asynchron zu den restlichen Modulen ablaufen. Aufgrund des sequentiellen Charakters der Software ist die Eigenständigkeit der Threads jedoch begrenzt, da Abhängigkeiten zu den Berechnungen vorhergehender Module bestehen. Die durchschnittlichen Bearbeitungszeiten für die verschiedenen Threads sind zusammen mit dem jeweiligen Modulbereich in Tabelle 5.14 dargestellt. Zum Test wurde eine Aufnahme der in Abbildung 5.11 dargestellten Leiterplatte verwendet.

Insgesamt zeigt sich, dass die Berechnungszeit der einzelnen Module wie auch die Anzahl der verwendeten Zeitmesswerte (in Klammern angegeben) stark variiert. Die

| Modul              | Bereich         | Zeit             |
|--------------------|-----------------|------------------|
| Zuschnitt 2D       | Vorverarbeitung | 139 $\mu$ s (23) |
| Entzerrung 2D      | Vorverarbeitung | 22 ms (23)       |
| Zuschnitt 3D       | Vorverarbeitung | 4 $\mu$ s (2372) |
| Zeilenspeicher 3D  | Vorverarbeitung | 24 $\mu$ s (977) |
| Synchronisierung   | Vorverarbeitung | 11 $\mu$ s (6)   |
| PCB Segmentierung  | Segmentierung   | 59 ms (6)        |
| Datenanpassung     | Segmentierung   | 1 ms (4)         |
| PCB RANSAC         | Segmentierung   | 242 ms (6)       |
| Morph. Operationen | Segmentierung   | 25 ms (4)        |
| BLOB               | Segmentierung   | 5 ms (4)         |
| Merkmalsberechnung | Merkmalsberech. | 12 ms (4)        |
| Random Forest      | Klassifikation  | 9 ms (4)         |
| Datenfusionierung  | Klassifikation  | 6 ms (4)         |

**Tabelle 5.14:** Durchschnittliche Ausführungszeiten der einzelnen Softwaremodule

Gesamtverzögerung liegt unter einer Sekunde und ist im Rahmen des Laborbetriebs ausreichend gering. Die Variation der Anzahl der Zeitmessungen begründet sich mit der unterschiedlichen Häufigkeit, mit der die Module durchlaufen werden. Module der Vorverarbeitung werden beispielsweise immer ausgeführt. Die nachfolgenden Module werden hingegen nur ausgeführt, wenn in den Messungen eine Leiterplatte enthalten ist.

Die längste Berechnungsdauer mit 242 ms pro Durchlauf besitzt das Modul zur Detektion der Leiterplattenebene mittels RANSAC. Die hohe Dauer ergibt sich aus der Vielzahl der nötigen Berechnungen. In der aktuellen Implementierung muss das Modul mehrmals Ebenengleichungen für 1 Million Messpunkte lösen. Ein Ansatz zur Beschleunigung könnte daher die Senkung der verwendeten Messungen sein. Der Zeitaufwand könnte z. B. um den Faktor 100 gesenkt werden, falls nur jede zehnte Messung in x- und y-Richtung zur Ebenenberechnung herangezogen werden würde.

Die morphologischen Operationen zur Detektion der Leiterplatte (beschrieben in Abb. 5.4) und zur Nachfilterung der Bauteilpunkte (beschrieben in Abb. 5.7) weisen mit 59 ms bzw. 25 ms ebenfalls eine verhältnismäßig lange Berechnungsdauer auf. Um hier eine höhere Performance zu erreichen, könnten die verwendeten Binärbilder zuvor in der Auflösung reduziert werden. Das Ergebnis könnte anschließend mittels entsprechender Streckung wieder zurückgerechnet werden.

Eine weitere Möglichkeit zur Beschleunigung der Software besteht in einer Verlagerung der Berechnungen von dem Hauptprozessor (engl. central processing unit, CPU) auf die Grafikkarte (engl. graphics processing unit, GPU). Je nach verwendeter Hardware ist dabei eine Beschleunigung um den Faktor 10 bis 100 für parallelsierbare Module zu erwarten.



# 6 Pilotanlage zur Bauteil- extraktion

In diesem Kapitel wird die anschließende Verarbeitung der Leiterplatten auf Basis der Erkennungsdaten geschildert. Diese findet in Form einer automatischen, gezielten Entnahme einzelner Komponenten statt. Aufgrund ihres hohen Materialwerts werden hierfür insbesondere Tantalkondensatoren betrachtet. Für die Entnahme wurde ein prototypisches Robotersystem entwickelt, das mittels Heißluft und Absaugung bzw. Druckluft Bauteile extrahieren kann<sup>11</sup>. Zur Evaluierung der Wirtschaftlichkeit wurden damit verschiedene Parameter getestet, die Einfluss auf die Energiebilanz haben und sich auf großtechnische Anlagen extrapolieren lassen.

## 6.1 Robotergestützte Bauteilextraktion


Das System besteht aus einem Roboter vom Typ Stäubli RX90 (108 kg Gesamtgewicht, 6 kg nominale Last) mit sechs Achsen, der über einem Eisengitter verfahren werden kann. Oberhalb des Gitters befindet sich eine Kamera, deren optische Achse im Lot zu dem Gitter ausgerichtet ist. Seitlich der Kamera sind mehrere Beleuchtungseinheiten angebracht. Die Kamera dient der Erkennung der Orientierung der Leiterplatten im Roboterkoordinatensystem. Die Koordinaten der detektierten Komponenten werden entsprechend umgerechnet und zur Extraktion an den Roboter weitergeleitet. Der Aufbau ist in Abb. 6.1 zu sehen. Für den Roboter wurde ein spezieller Aufsatz entwickelt, dessen Entwicklung im nächsten Abschnitt 6.1.1 beschrieben ist. Die Software zum Betrieb der Anlage ist in Abschnitt 6.1.2 näher erläutert.

### 6.1.1 Entwicklung einer Extraktionsmethode

Zur selektiven Extraktion von Bauteilen wurden mehrere Verfahren miteinander verglichen. Grundsätzlich gibt es viele verschiedene Ansätze, die sich jedoch vorrangig

---

<sup>11</sup>Das System wurde in Zusammenarbeit mit Marco Ziemer aufgebaut. [Zie17]



**Abbildung 6.1:** Kompletter Aufbau zur Extraktion der Bauteile

| # | Verfahren                    | Kurzerläuterung                                   |    |
|---|------------------------------|---|----|
| 1 | Heißluft & Infrarotstrahlung | Aufschmelzung der Lötkontakte                     | +  |
| 2 | Laserentlötung               | Erhitzung der Lötstellen mittels Laser            | +  |
| 3 | Laserschneiden               | Ausschneiden von Komponenten inkl. Leiterplatte   | -  |
| 4 | Laserdelamination            | Delamination des Kontaktes von der Leiterplatte   | ++ |
| 5 | Abfräsen                     | Mechanische Krafteinwirkung auf Bauteile          | -  |
| 6 | Elektrohydraulische Zerkl.   | Mechanische Schockwellen durch Funkenentladung    | -  |
| 7 | Heiße Flüssigkeit            | Eintauchen in heiße Flüssigkeit, Entlötung        | -  |
| 8 | Chemie                       | Auflösen der Lötverbindung, z.B. mit HCl          | -  |
| 9 | Kryotechnisch                | Tieftemperaturbehandlung, Aufbrechen der Kontakte | -  |

**Tabelle 6.1:** Nicht vollständige Aufzählung der verschiedenen Verfahren zur Bauteil-extraktion inklusive Bewertung (+,-) für den aktuellen Fall

mit der nicht selektiven Extraktion beschäftigen. Die Verfahren lassen sich grob in die vier Kategorien thermische, mechanische, chemische und kombinierte Extraktion einteilen und sind in Tabelle 6.1 aufgeführt.


Verfahren 1 wird in der Industrie in großtechnischem Maßstab in Form von Reflow-Öfen eingesetzt, um die Leiterplatten zu bestücken. Darüber hinaus kommt es auch im sog. Rework-Sektor zum Austausch von Komponenten in Kleinserien und in prototypischen Extraktionsanlagen zum Einsatz, weshalb es als erfolgversprechend gilt. [Mel13], [Kop16]

Verfahren 2 wurde im Rahmen dieser Arbeit mit einer Industrielaseranlage getestet. Es erscheint mäßig erfolgversprechend, da die Lötstellen der Tantalkondensatoren nur für einen sehr kurzen Zeitraum erwärmt werden und die erste Stelle bereits erkaltet, während der Laser zur zweiten Lötstelle unterwegs ist. Außerdem sind bei einigen Tantalkondensatoren Lötstellen nur unter dem Bauteil, aber nicht seitlich vorhanden. Für die Entlötung von ICs wurde das Verfahren jedoch erfolgreich von Hanreich et al. eingesetzt. [HWN01]

Verfahren 3 wurde ebenfalls im Rahmen dieser Arbeit getestet. Je nach verwendetem Laser fällt dabei der nötige Einsatz eines Prozessgases zum Abtransport des Schnittmaterials negativ ins Gewicht. Zusätzlich fielen herausgeschnittene Bauteile im Test nicht einfach heraus, sondern blieben aufgrund der rauen Schnittoberfläche in der Leiterplatte hängen. Aus diesem Grund wurde das komplette Herausschneiden insgesamt negativ bewertet.

Verfahren 4 wurde während des Tests der Verfahren 2 und 3 entdeckt<sup>12</sup>. Es beruht auf dem Effekt, dass sich Löt pads auf der Leiterplatte ablösen lassen, falls durch einen Laser genug Hitze ins Material eingebracht wird. Anhand eines nicht näher untersuchten Prozesses konnte dabei die Verbindung zwischen dem metallischen Löt pad auf der Leiterplatte und der Leiterplatte selbst gelöst werden. Die Kondensatoren

<sup>12</sup>Diese Tests wurden in ähnlicher Weise bereits von einem Kooperationspartner durchgeführt und mündeten wahrscheinlich ebenfalls in Verfahren 4.




**Abbildung 6.2:** Delaminierte Tantalkondensatoren (rechts) nach Behandlung der Löt pads mit einem Laser (links)

auf den behandelten Löt pads waren anschließend nicht mehr stoffschlüssig mit der Leiterplatte verbunden und konnten ohne Kraftaufwand entfernt werden. Mit der verwendeten Laseranlage konnten mehrere Kondensatoren innerhalb weniger Sekunden erfolgreich abgelöst werden. Abb. 6.2 zeigt das Resultat. Als problematisch ist dabei jedoch die starke Belastung der Abluft zu sehen, die eine entsprechende Reinigungsanlage erfordert. Ferner konnte bei den durchgeführten Tests keine Gefahr durch Entflammung der untersuchten Leiterplatten festgestellt werden. Nach Kelley werden Leiterplatten vor allem im Gütegrad FR-4, bestehend aus Epoxidharz und Glasfasergewebe, hergestellt [Kel08, S. 6.4]. Deren Brennbarkeit ist typischerweise nach den Definitionen 94V-0, 94V-1 und 94V-2 der Underwriters Laboratories als selbstverlöschend festgelegt [Kel08, S. 6.5-6.8, S. 8.12 f].

Die Verfahren 3 sowie 5 bis 9 erscheinen vor dem Hintergrund der selektiven Bauteilextraktion aufgrund folgender Gründe als wenig sinnvoll:

- Nicht vorhandene Selektivität (6, 7, 8) [Eng97]
- Übermäßiger Materialeinsatz (3, 5, 7, 8)
- Fragwürdige (3) oder nicht gegebene Funktion (9) [Yua+07]


Auf Basis der Evaluierung der genannten Verfahren wurde ein eigenes selektives Entstückungssystem für einen Industrieroboter im Labormaßstab entwickelt, das mittels Heißluft, Absaugung und Druckluft arbeitet. Dazu wurde ein Werkzeug aufgebaut, das die Möglichkeit bietet, gezielt Lötverbindungen zu lösen und die betroffenen Bauteile einzusaugen oder wegzupusten. Damit stehen Optionen zur Verfügung, die auch in großen Anlagen umgesetzt werden können. Zur Stabilität wurde der Aufsatz aus Stahl gefertigt und fest verschraubt. Entsprechende Befestigungspunkte ermöglichen eine einfache Einstellung der Positionen der eingesetzten Komponenten. Der Aufsatz ist in Abbildung 6.3 dargestellt.



**Abbildung 6.3:** Entwickeltes Werkzeug zur automatischen Bauteilextraktion

## 6.1.2 Software zur Bauteilextraktion

Der genaue Ablauf innerhalb der Software zur Steuerung des Extraktionssystems ist in Abbildung 6.4 zu sehen. In einem ersten Schritt werden die Positionsdaten aus der Erkennungsanlage in das Roboterkoordinatensystem umgerechnet, wobei auch eine Verdrehung und Verschiebung der Leiterplattenposition in dem Entstückungssystem berücksichtigt wird. Die Verdrehung und Verschiebung der Leiterplatte folgt aus dem Einsatz zweier getrennter Systeme für Erkennung und Extraktion und dem manuellen Transfer der Leiterplatten zwischen den Systemen. Zur Umrechnung werden die Daten aus der Erkennungsanlage für eine Leiterplatte eingelesen. Diese bestehen im Wesentlichen aus Positionsangaben der einzelnen Bauteile sowie den synchronisierten 2D- und 3D-Daten der zu bearbeitenden Leiterplatte. Zur Identifikation der Orientierung im Robotersystem wird weiterhin jeweils ein 2D-Bild der Entstückungseinheit mit und ohne Leiterplatte mit der Kamera aus dem Robotersystem aufgenommen. Anschließend findet eine Vordergrund-Hintergrund-Subtraktion mit anschließender BLOB-Extraktion statt, um die Leiterplatte im 2D-Bild zu identifizieren. Auf beiden Leiterplattenbildern werden nun Extrempunkte und zugehörige Merkmale mittels A-KAZE berechnet und anschließend einander zugeordnet. Aus dem Matching ergeben sich zusammengehörige Punkte, die zur Berechnung der Verschiebung und Rotation genutzt werden. Diese werden anschließend auf die Positionsdaten angewendet, sodass diese nun im Roboterkoordinatensystem liegen.




**Abbildung 6.4:** Darstellung des Ablaufs zur Extraktion einzelner Bauteile

Im nächsten Schritt werden die zu extrahierenden Komponenten auf eine mögliche Extraktion hin geprüft. Dazu wird die Umgebung jeder Komponente auf störende benachbarte Bauteile hin untersucht. Insbesondere bei dicht bestückten Leiterplatten kommt es vor, dass Bauteile von anderen verdeckt werden oder sich zumindest in geringem Abstand zu anderen Bauteilen befinden, sodass eine Extraktion nicht immer möglich ist. Ein Beispiel dafür ist in Abbildung 6.5 dargestellt. Hier verhindert der hohe Stecker auf der linken Seite den Einsatz eines Werkzeugs, das zur Extraktion nahe an den Kondensator heranzufahren muss.


Im letzten Schritt werden die Daten der Bauteile, die nach der vorhergehenden Überprüfung als extrahierbar gelten, an den Roboter zur Extraktion weitergeleitet. Bei mehreren Komponenten werden die geometrischen Entfernungen untersucht und die Werkzeugeinheit so verfahren, dass sich ein geringer Gesamtweg für den Roboter ergibt. Durch die Form des Aufsatzes begründet fährt der Roboter jedes Bauteil von oben an, um Zusammenstöße mit hervorstehenden Leiterplattenbauteilen beim Verfahren zu vermeiden.

### 6.1.3 Evaluierung und Effizienz

Zur Evaluierung des Entstückungssystems wurden 47 gleich bestückte Leiterplatten angeschafft. Es handelt sich dabei um eine veraltete Grafikkarte von 1999, die jeweils mit 9 Tantalkondensatoren und 7 integrierten Schaltungen bestückt ist. Der genaue



**Abbildung 6.5:** Darstellung der problematischen Umgebung eines Tantalkondensators (gelb) auf einer Leiterplatte



**Abbildung 6.6:** Leiterplattenset zur Evaluierung der Extraktion von Tantalkondensatoren und ICs

Typ der verwendeten Grafikkarte lautet „Number Nine SR9 AGP SDRAM NLX 8MB“. Die Variationen innerhalb des Sets (Abbildung 6.6) beschränken sich auf die Farbe und Größe der verbauten Tantalkondensatoren.

In Bezug auf die Extraktion der Tantalkondensatoren wurde neben der Wiederholgenauigkeit auch die minimale Aufheizdauer mittels Heißluft ausgewertet, nach der diese extrahierbar sind. Dazu wurden die Kondensatoren in mehreren Schritten von 10s bis 46s jeweils einzeln erwärmt und abgesaugt. Um Streuungen vorzubeugen, wurde der Heißluftfön vor jedem Durchlauf 120s betrieben und für jeden Zeitschritt 4 verschiedene Platinen untersucht. Für den Test mit 10s standen nur noch zwei Leiterplatten zur Verfügung. Außerdem wurde der Winkel der Leiterplatten zum Extraktionssystem variiert. Die Anzahl der zur Evaluierung extrahierten Kondensatoren wurde anschließend als Vergleich herangezogen und ist in Tabelle 6.2 absolut („Resultat“) und prozentual („Rate“) angegeben. Zum Test wurden nur 7 der 9 Kondensatoren angefahren.

Aus den durchgeführten Tests lässt sich erkennen, dass eine Aufheizdauer von 34s die beste Extraktionsquote erzeugt. Auffallend ist darüber hinaus die leichte Abnahme der Extraktionsquoten ab einer Aufheizdauer von 38s. Die Ursache hierfür konnte letztlich nicht geklärt werden. Die naheliegende Vermutung der Verwendung eines Lötzinns mit höherem Schmelzpunkt kann durch die gemischte Auswahl an Leiterplatten relativ sicher ausgeschlossen werden. Denkbar ist, dass manche Bestandteile des Lötzinns durch die hohen Temperaturen, die bei der Erhitzung über 38s und mehr erzielt wurden, verdampfen, wodurch die zurückbleibende Masse zäher wird und sich das verlötete Bauteil dadurch schwerer ablösen bzw. absaugen lässt.

Bei der Durchführung der Extraktion der ICs wurde neben der Aufheizdauer zusätzlich der verwendete Druck für die Druckluft getestet, mit dem die erwärmten ICs von der Leiterplatte gelöst werden. Um den minimal notwendigen Druck zu identifizieren,

| Dauer | Resultat | Rate |
|-------|----------|------|
| 46 s  | 18/28    | 64 % |
| 42 s  | 17/28    | 60 % |
| 38 s  | 16/28    | 57 % |
| 34 s  | 22/28    | 79 % |
| 30 s  | 21/28    | 75 % |
| 26 s  | 21/28    | 75 % |
| 22 s  | 21/28    | 75 % |
| 18 s  | 10/28    | 36 % |
| 14 s  | 6/28     | 21 % |
| 10 s  | 2/14     | 14 % |

**Tabelle 6.2:** Evaluierung der Tantalextraktion durch Heißluft und Absaugung mit unterschiedlichen Aufheizzeiten

wurden zwei Leiterplatten während einer langen Aufwärmphase durch zwei Heißluftföhne erhitzt, sodass der Schmelzpunkt des Lots sicher erreicht werden konnte. Mit diesem Verfahren konnten ICs bereits mit einem Druck von 0,5 bar von der Platine entfernt werden. Anschließend wurden weitere Tests unter Verwendung der Heißluftzuführung aus der Extraktionsanlage durchgeführt, deren Resultate in Tabelle 6.3 zu sehen sind. Um Streueffekte zu minimieren, wurden jeweils zwei Leiterplatten mit den gleichen Parametern behandelt.

| Dauer | Druck | Resultat | Rate  |
|-------|-------|----------|-------|
| 80 s  | 4 bar | 8/8      | 100 % |
| 70 s  | 4 bar | 8/8      | 100 % |
| 60 s  | 4 bar | 8/8      | 100 % |
| 50 s  | 4 bar | 7/8      | 88 %  |
| 40 s  | 4 bar | 6/8      | 75 %  |
| 40 s  | 5 bar | 3/8      | 38 %  |
| 40 s  | 6 bar | 8/8      | 100 % |
| 35 s  | 4 bar | 3/8      | 38 %  |
| 35 s  | 6 bar | 5/8      | 63 %  |
| 30 s  | 4 bar | 1/8      | 13 %  |
| 30 s  | 6 bar | 0/8      | 0 %   |

**Tabelle 6.3:** Evaluierung der Extraktion von ICs mit unterschiedlichen Aufheizzeiten und Drücken

Die Resultate der Extraktion der untersuchten ICs zeigen, dass ICs mit dem aufgebauten Aufsatz mindestens 60 s erwärmt werden müssen, um eine sichere Extraktion bei 4 bar zu gewährleisten. Aufgrund des relativ hohen Vorkommens von ICs auf Leiterplatten ist die Aufheizdauer als zu hoch einzuschätzen, um in einem wirtschaftlichen Prozess eingesetzt zu werden. Alternative Ansätze werden daher im nächsten Abschnitt erläutert.

## 6.2 Wirtschaftlichkeitsrechnung

Anlagen in der Industrie unterliegen hohen Anforderungen an die Wirtschaftlichkeit. Im Recyclingumfeld sind dazu insbesondere der Durchsatz und die laufenden Kosten einer Anlage von Interesse. Auch der Anschaffungspreis spielt eine Rolle. Nachfolgend wird zuerst eine Abschätzung für die aufgebaute Laboranlage inkl. Detektion auf Basis einer Extraktion von Tantalkondensatoren geliefert. Anschließend wird eine mögliche Umsetzung in großtechnischen Verfahren diskutiert<sup>13</sup>.

### 6.2.1 Pilotanlage

Die Energieverbraucher des Komplettsystems bestehend aus Detektion und Extraktion sind in Tabelle 6.4 mit ihrer Leistungsaufnahme  $P$  aufgeführt. Zur Übersichtlichkeit wurde das System in die Modi  $M_1$  bis  $M_{4.1}$  bzw.  $M_{4.2}$  aufgeteilt, die bis auf die letzten beiden konsekutiv miteinander verbunden sind:

- $M_1$ : Komplette Vermessung einschließlich Klassifikation der Komponenten mit der Erkennungsanlage
- $M_2$ : Anfahrmodus des Roboters an die Positionen der Komponenten
- $M_3$ : Aufheizen der Komponenten mit dem Heißluftföhn
- $M_{4.1}$ : Absaugen der Tantalkondensatoren
- $M_{4.2}$ : Wegblasen der Tantalkondensatoren mit Druckluft (1 bar)

Der Energiebedarf ist dementsprechend in  $E_1$  bis  $E_{4.1}$  bzw.  $E_{4.2}$  in der Tabelle untergliedert. In jedem Modus tragen unterschiedliche Verbraucher zur Bilanz bei, während die restlichen deaktiviert sind. Da der Energieverbrauch teilweise von der Anzahl der Kondensatoren abhängt, wurde zur Berechnung die durchschnittliche Bestückung von 20 Tantalkondensatoren je Notebookplatine angenommen. Diese Zahl wurde auf Basis von 13 Notebookleiterplatten ermittelt, die dem Autor von einem lokalen Recyclingunternehmen zur Verfügung gestellt wurden. Aufgrund von beidseitig bestückten Leiterplatten wurde angenommen, dass alle Leiterplatten zweimal durch das System fahren. Die Dauer der Detektion einer Leiterplatte (20 s) ergibt sich aus der Förderbandgeschwindigkeit von 2 m/min in Kombination mit 30 cm langen Leiterplatten und den zwei Durchläufen.

---

<sup>13</sup>Die Wirtschaftlichkeitsberechnungen wurden in Zusammenarbeit mit Maximilian Kern durchgeführt. [Ker18]

| Verbraucher  | $P_{in}$ | $E_1$   | $E_2$ | $E_3$    | $E_{4.1}$ | $E_{4.2}$ |
|--------------|----------|---------|-------|----------|-----------|-----------|
| Dauer        | -        | 20 s    | 100 s | 440 s    | 40 s      | 20 s      |
| PC           | 90 W     | 1,8 kJ  | 9 kJ  | 39,6 kJ  | 3,6 kJ    | 1,8 kJ    |
| Förderband   | 35 W     | 700 J   | -     | -        | -         | -         |
| Kameras      | 4 W      | 80 J    | -     | -        | -         | -         |
| Laserscanner | 11 W     | 220 J   | -     | -        | -         | -         |
| Beleuchtung  | 149 W    | 2,98 kJ | -     | -        | -         | -         |
| Roboter      | 570 W    | -       | 57 kJ | 250,8 kJ | 22,8 kJ   | 11,4 kJ   |
| Heißluft     | 460 W    | -       | -     | 202,4 kJ | -         | -         |
| Absaugung    | 1060 W   | -       | -     | -        | 42,4 kJ   | -         |
| Druckluft    | 2080 W   | -       | -     | -        | -         | 41,6 kJ   |
| Gesamt       | 4774 W   | 5,78 kJ | 66 kJ | 492,8 kJ | 68,8 kJ   | 54,8 kJ   |

**Tabelle 6.4:** Auswertung des Energiebedarfs zur Bearbeitung einer Leiterplatte

Beim Vergleich des Energiebedarfs fällt auf, dass die Aufheizphase am meisten Energie benötigt. Die größten Verbraucher über alle Modi sind der eingesetzte Roboter und der Heißluftfön, die zusammen etwa 84 % der umgesetzten Energie benötigen. Die optischen Sensoren fallen dabei mit etwa 0,05 % kaum ins Gewicht. Darüber hinaus fällt auf, dass die Verwendung der Absaugung und der Druckluft sich hinsichtlich des Energiebedarfs ähnlich verhält. Die Gesamtdauer zur Bearbeitung einer Leiterplatte dauert (bei 100 % Erkennungsrate) bei Absaugung 600 s und bei Druckluft 580 s. Die Verwendung von Druckluft ist insgesamt also etwas energiesparender und schneller.

Zur Entstückung einer Leiterplatte mit dem Pilotsystem ergibt sich je Leiterplatte ein Gesamtenergiebedarf von 0,63 MJ mit Absaugung bzw. 0,62 MJ mit Druckluft. Ausgehend von einem Preis von 0,28 €/kWh ergeben sich daraus im Falle der Absaugung Energiekosten von etwa 0,049 €. Davon entfallen anteilmäßig 0,00045 € auf die reine Detektion und 0,04881 € auf die Extraktion. Bei Einsatz von Druckluft betragen die Energiekosten etwa 0,048 €. Aussagekräftig werden diese Werte, wenn sie ins Verhältnis zum Gesamtwert der extrahierten Tantalkondensator-Fraktion gesetzt werden. Dieser beträgt je Notebookplatine etwa 0,077 €. Die Berechnung dieses Werts ist im Anhang auf Seite 92 beschrieben.

Neben den Energiekosten ist der Durchsatz eine wichtige Kenngröße zur Bestimmung der Wirtschaftlichkeit. Der mit dem Absaugverfahren erzielbare Durchsatz liegt bei etwa 6 Leiterplatten in der Stunde, was auf die langsame Extraktion zurückgeht. Die Erkennungsanlage besitzt im Vergleich dazu einen Durchsatz von etwa 180 (doppelseitig) bzw. 360 (einseitig) Leiterplatten pro Stunde. Die Gesamtanlage würde damit im 24/7-Betrieb bei einer Erfolgsquote von 75 % bei der Extraktion und 80 % bei der Detektion gem. Gl. 6.1 Kondensatoren im Materialwert  $U_1$  von circa 370 € pro Jahr erwirtschaften. Die Detektionsrate von 80 % setzt sich hier-

bei aus der Segmentierungsrate von 83 % und einer TP-Rate von 96 %, jeweils für Tantalkondensatoren, zusammen. Zur vereinfachten Abschätzung wird dabei nicht berücksichtigt, dass die Energiekosten zur Detektion statt zu 80 % tatsächlich zu 100 % eingehen müssen. Der dadurch entstehende Fehler kann aufgrund des Verhältnisses von Detektions- zu Extraktionsenergiekosten vernachlässigt werden. Außerdem werden weitere Verunreinigungen durch Falscherkennungen, die etwa 7 % der detektierten Tantalkondensatoren ausmachen, nicht berücksichtigt. Weiterhin werden die Verunreinigungen durch schwarze Dioden, die optisch kaum von schwarzen Tantalkondensatoren unterscheidbar sind, vernachlässigt.

$$U_1 = 8760 \text{ h} \times 6/\text{h} \times (0,077 \text{ €} \times 75 \% - 0,049 \text{ €}) \times 80 \% = 368 \text{ €} \quad (6.1)$$

Gegenüber dem extrahierten Materialwert stehen jedoch noch Investitionskosten in Höhe von 45000 € bzw. 4500 € bei einer Abschreibung über 10 Jahre. Darin enthalten sind der Roboter und die optischen Sensoren mit jeweils etwa 20000 € sowie weiteres Material. Einkaufspreise für die Leiterplatten werden in diesem Zusammenhang nicht berücksichtigt, da die alleinige Aufarbeitung des Tantals wirtschaftlich nicht sinnvoll ist. Stattdessen soll das Verfahren einen Mehrwert zusätzlich zur normalen Aufbereitung, wofür die Leiterplatten ursprünglich erworben wurden, bieten.

Um die Extraktion von Tantalkondensatoren wirtschaftlich umsetzen zu können, muss das gesamte Verfahren und insbesondere die Extraktion wesentlich schneller ablaufen. Ausgehend von dem hier beschriebenen Labormaßstab werden deshalb im nächsten Abschnitt Möglichkeiten zur Umsetzung im Industriemaßstab behandelt.

## 6.2.2 Umsetzung in großtechnischen Verfahren

Um das vorgestellte Verfahren großtechnisch umsetzen zu können, bieten sich verschiedene Möglichkeiten. Nachfolgend werden davon zwei Möglichkeiten beschrieben, die dem Autor besonders sinnvoll erscheinen:

- Laserdelamination mit einem leistungsstarken Industriesystem
- Komplette Erwärmung der Leiterplatte und selektive Druckluftextraktion

Das Verfahren der Laserdelamination erscheint vor dem Hintergrund der selektiven Extraktion besonders vielversprechend. Darüber hinaus besitzt das Verfahren eine verhältnismäßig günstige Energiebilanz, die auf Basis der in Abschnitt 6.1.1 beschriebenen Versuche in Tabelle 6.5 umgerechnet worden ist. Im Versuch wurde ein 60-W-Laser mit einer Anschlussleistung von ca. 1,2 kW getestet. Ein größeres System, beispielsweise mit 250 W, besitzt demnach etwa 5 kW Anschlussleistung und benötigt maximal 2 s zur Delamination eines Kondensators. Beim Einsatz eines

solchen Lasers in Kombination mit leistungsstarker Hardware zur Detektion ergibt sich ein Gesamtenergiebedarf von 210 kJ für die Extraktion einer durchschnittlichen Leiterplatte aus Notebooks, wodurch Kosten in Höhe von 0,016 € je Leiterplatte entstehen. Davon entfallen 0,01587 € auf die Extraktion und 0,00044 € auf die Detektion. Der steuernde PC wurde mit einer Leistungsaufnahme von 2 kW im Falle der Detektion und 100 W bei der Lasersteuerung angenommen.

| Verbraucher  | $P_{in}$   | $E_1$  | $E_{4.3}$ |
|--------------|------------|--------|-----------|
| Dauer        | -          | 2 s    | 40 s      |
| PC           | 2 kW/100 W | 4 kJ   | 4 kJ      |
| Förderband   | 500 W      | 1 kJ   | -         |
| Kameras an   | 50 W       | 100 J  | -         |
| Laserscanner | 100 W      | 200 J  | -         |
| Beleuchtung  | 200 W      | 400 J  | -         |
| Laser        | 5 kW       | -      | 200 kJ    |
| Gesamt       | 7,85 kW    | 5,7 kJ | 204 kJ    |

**Tabelle 6.5:** Abschätzung des Energiebedarfs zur Detektion ( $E_1$ ) und anschließenden Extraktion von Tantalkondensatoren durch Laserdelamination ( $E_{4.3}$ )

Der Durchsatz eines solchen Systems beträgt ca. 90 Leiterplatten in der Stunde. Aufbauend auf den Erfolgsraten von 80 % für die Detektion und 75 % für die Extraktion resultiert daraus pro Jahr im 24/7-Betrieb ein extrahierter Materialgegenwert  $U_2$  von ca. 26300 € aus dem extrahierten Tantal-Material gem Gl. 6.2. Die Kosten für die Anschaffung des vorgeschlagenen Systems schätzt der Autor auf etwa 100000 € ein, wodurch sich bei 10 Jahren Laufzeit eine Abschreibung von 10000 € pro Jahr ergibt (Tabelle 6.6). Damit amortisiert sich das System, wenn es während der 10 Jahre zu etwa 40 % in Betrieb ist. Löhne, anfallende Reparaturkosten und andere indirekte Kosten bleiben dabei unberücksichtigt, ebenso wie die bereits im letzten Abschnitt vernachlässigten Faktoren.

$$U_2 = 8760 \text{ h} \times 90/\text{h} \times (0,077 \text{ €} \times 75 \% - 0,016 \text{ €}) \times 80 \% = 26333 \text{ €} \quad (6.2)$$

Das zweite Verfahren wurde mit dem beschriebenen Aufbau angenähert. Um die gewünschte Energie auf die Leiterplatte aufzubringen, könnte im großtechnischen Maßstab eine Art großer Reflow-Ofen verwendet werden. Um einen entsprechenden Durchsatz zu generieren, ist hierfür jedoch entweder eine sehr hohe Temperatur oder ein langer Ofen nötig. Die Anschlussleistung schätzt der Autor auf Werte jenseits von 10 kW ein. Neben der zur Erhitzung eingesetzten Energie wird auch Druckluft benötigt, die einen weiteren Kostenfaktor in Recyclingsystemen darstellt. Insgesamt erscheint deshalb die Laserdelamination als geeigneteres Verfahren zur Extraktion.

| <b>Einheit</b>  | <b>Kosten</b> | <b>Beschreibung</b>            |
|-----------------|---------------|--------------------------------|
| Lasersystem     | 50000 €       | Lasereinheit und Kinematik     |
| Optik & Scanner | 30000 €       | Optische Sensoren              |
| Förderband      | 10000 €       | Förderband und Aufbau          |
| Recheneinheit   | 10000 €       | Steuerung und Bildverarbeitung |
| Gesamt          | 100000 €      |                                |

**Tabelle 6.6:** Abschätzung der Systemkosten



## 7 Ergebnisse und abschließende Betrachtungen

Das Ergebnis der Arbeit ist eine vom Ansatz her neuartige, voll funktionsfähige Pilotanlage, die die automatisierte Erkennung von Bauteilen auf Leiterplatten und deren selektive Extraktion ermöglicht. Damit können, anders als in bisherigen Industrieverfahren, gezielt wertstoffhaltige Komponenten mit einem hohen Anteil an HT-Metallen vollautomatisch aus Leiterplatten entfernt werden.

Zur Erkennung kommt eine Sensorkombination aus einem 3D-Linienscanner für die Höherfassung und einer 2D-Farbkamera über einem Förderband zum Einsatz. Das Förderband wurde zur Sicherstellung der Industrietauglichkeit gewählt und besitzt eine Geschwindigkeit von 2 m/min. Beide Sensoren sind an ein Softwaresystem angebunden und werden mittels eines im Förderband eingesetzten Gebers ausgelöst.

Das Softwaresystem besteht aus mehreren Verarbeitungseinheiten, die nacheinander die Verarbeitung der Daten sicherstellen. Die Module laufen innerhalb eigener Threads ab und sind zur Parallelisierung asynchron miteinander verbunden. Sie lassen sich in Dateneingang, Vorverarbeitung, Segmentierung, Merkmalsberechnung und Klassifizierung einteilen. In der Vorverarbeitung werden die Eingangsdaten entzerrt, kalibriert und synchronisiert. Anschließend identifiziert eine BLOB-Detektion mit vorangehender Morphologie einzelne Leiterplatten und die dazugehörigen Messpunkte. Im Rahmen der Segmentierung werden diese Daten dann genutzt, um über die Leiterplattenebene Messpunkte der Komponenten zu identifizieren. Einzelne Komponenten werden durch erneute BLOB-Detektion mit vorangehender Morphologie identifiziert. Die Parameter dieser morphologischen Operationen wurden über eine umfangreiche Parametersuche optimiert. Die resultierenden BLOBs umfassen je nach Bauteilgröße Messpunkte im Umfang von wenigen 100 bis hin zu mehreren 10000 Punkten.

Im Rahmen der Merkmalsberechnung werden auf Basis der segmentierten Komponentendaten aussagekräftige Merkmale berechnet. Um eine möglichst optimale Merkmalsberechnung sicherzustellen, wurden ebenfalls verschiedene Auswertungen durchgeführt. Insgesamt hat sich dabei gezeigt, dass vergleichsweise simple Kenngrößen, wie z.B. mittlere Höhe, Fläche, Farbe oder Umfang, sehr gute Resultate liefern.

Die anschließende Klassifikation bestimmt die Klassenzugehörigkeit der Bauteile anhand der errechneten Merkmale. Im Rahmen der Arbeit wurden insgesamt 19 Bauteilklassen eingeführt. Da die Detektionsrate mit mehr Klassen typischerweise schlechtere Resultate liefert, wurden diese zu fünf verschiedenen Überklassen zusammengefasst. Im Rahmen der Arbeit wurden insgesamt vier verschiedene Klassifikatoren untersucht und mit einer Datenbank von insgesamt ca. 13000 Komponenten ausgewertet. Neben dem RF wurden auch eine SVM, ein KNN und ein hochmodernes CNN untersucht. Der RF erzielte dabei mit einer Klassifikationsrate von 94,34 % für das selbst entwickelte GFSK-Merkmal das beste Resultat, weshalb dieser auch im Softwaresystem in Kombination mit dem GFSK-Merkmal eingesetzt wird.

Nach der Bauteilerkennung können die Klassifikationsergebnisse über eine Schnittstelle an ein System zur prototypischen Bauteilextraktion weitergeleitet werden. Dieses System wurde zur Evaluierung der Extraktion von Komponenten aus Elektroschrott aufgebaut und besteht aus einem Roboter in Kombination mit einem selbst entwickelten Werkzeug zur gleichzeitigen Anwendung von Heißluft, Absaugung oder Druckluft. Der ganze Aufbau wird von einer entsprechenden Software gesteuert, welche die anzufahrenden Komponenten auswählt, den Anfahrtswinkel bestimmt und den Werkzeugeinsatz steuert. Ein einfacher Wegfindungsalgorithmus ist ebenfalls eingebaut.

Im Rahmen des Systemaufbaus wurden weiterhin die Parameter für das Extraktionswerkzeug untersucht. Hierfür wurden ca. 45 gleichartige mit Tantalkondensatoren und ICs bestückte Leiterplatten verwendet. Der beste Parametersatz ermöglichte eine Extraktionsquote von ca. 79 % (Tantalkondensatoren) bzw. 100 % (ICs).

## 7.1 Wirtschaftliches Potential

Da die im Rahmen der Arbeit entwickelte Anlage möglichst praxisnah umgesetzt werden sollte, spielen neben der grundsätzlichen Funktion auch wirtschaftliche Überlegungen eine größere Rolle. Insbesondere wurden dazu eine Energieabschätzung und eine Kostenanalyse für den Geschäftsfall der Tantalextraktion durchgeführt. Die Wirtschaftlichkeit hängt in diesem Zusammenhang jedoch nicht nur von den technischen Rahmenbedingungen ab, sondern auch vom aktuellen Handelspreis für Tantal, der teilweise starken Schwankungen unterliegt [Deu17].

Das entwickelte Verfahren zur Erkennung ist (gegenüber der evaluierten Extraktion) sehr energieeffizient und bietet einen Durchsatz von ca. 300 einseitig bestückten Leiterplatten pro Stunde, was etwa 80 kg/h entspricht, wenn von einem durchschnittlichen Gewicht von 283 g und einer durchschnittlichen Größe von 30 cm × 20 cm je Leiterplatte ausgegangen wird. Für jede einzelne Platine wird etwa eine Energie von 2,89 kJ benötigt, was bei 0,28 €/kWh einem Preis von 0,00022 € pro Leiterplatte entspricht. Bei doppelseitig bestückten Leiterplatten wird die doppelte Energie benötigt.

Das System zur prototypischen Extraktion ist naturgemäß weniger effizient, da in diesem Schritt die Lötverbindungen aufgeschmolzen werden müssen. Darüber hinaus ist der Durchsatz von 1,68 kg Leiterplatten pro Stunde sehr gering. Der Energiebedarf bzw. die Kosten liegen hier bei ca. 630 kJ bzw. 0,049 € je Leiterplatte (bezogen auf Tantalkondensatoren). Das Spektrum der extrahierbaren Komponenten reicht jedoch über die hier im wirtschaftlichen Fokus liegenden Tantalkondensatoren hinaus. Dadurch bietet das untersuchte Verfahren eine gewisse Zukunftsfähigkeit. Selbst mit der aktuellen Pilotanlage lassen sich bereits mehrere Bauteilarten erkennen und auch extrahieren.

Eine Extrapolation auf Basis einer ebenfalls getesteten Laserextraktion macht das Gesamtsystem lohnenswert. Bei einer Investition von 100000 € amortisiert sich die vorgeschlagene Anlage bei etwa 40 % Betrieb über eine Laufzeit von 10 Jahren. Die für diese Abschätzung gewonnenen Daten basieren auf eigenen Auswertungen und einem Verkaufspreis von 38,25 €/kg für das verunreinigte Tantal, dessen Bestimmung im Anhang auf Seite 92 beschrieben ist. Der Leiterplatten-Durchsatz der vorgeschlagenen Anlage beträgt ca. 25 kg/h.

## 7.2 Mögliche Optimierungen

Da es sich bei der entwickelten Anlage um eine Pilotanlage handelt, bestehen vielfältige Möglichkeiten zur Optimierung. Ein vorrangiges Ziel wäre sicherlich die Erhöhung des Durchsatzes.

In der Erkennungsanlage kann der Durchsatz mit dem Einsatz von besserer Hardware für das Softwaresystem in Kombination mit schnelleren Sensoren und einem breiteren und schnelleren Förderband erhöht werden. Beispielsweise könnte eine hochauflösende Zeilenkamera in Verbindung mit einem Laserscanner der Schutzklasse 3 oder höher eingesetzt werden. Auch die Software an sich kann beschleunigt werden, indem rechenintensive Teile nicht auf dem Hauptprozessor, sondern auf der Grafikkarte berechnet werden. Weiterhin ist der Einsatz von Hardware auf Basis eines FPGAs (engl. field programmable gate array) denkbar, um Hochgeschwindigkeitsanforderungen zu erfüllen.

Zur Verbesserung der Detektionsrate wurden verschiedenste Ansätze untersucht. Der Einsatz auf Basis eines CNN soll dabei nicht unerwähnt bleiben. Im Test zeigte sich, dass das CNN trotz GPU-Beschleunigung für den bereits geschwindigkeitsreduzierten Pilotbetrieb um den Faktor 100 zu langsam ist. Eine Möglichkeit würde im kombinierten Einsatz mit dem 3D-Sensor bestehen, der die zu untersuchenden Bildteile vorauswählt. Durch die Reduktion der selektierten Regionen von aktuell  $10^6$  auf nur noch  $10^2$  bis  $10^3$  könnte eine proportionale Beschleunigung um den Faktor 1000 bis 10000 erreicht werden. Darüber hinaus könnte durch eine Berechnung der Leiterplattenausrichtung auf dem Förderband eine optimierte Merkmalsberechnung

der Form und Formpassung erfolgen. Außerdem würde dadurch die Beschränkung der Orientierungen in  $90^\circ$ -Schritte ( $\pm 10^\circ$ ) entfallen.

Bei der selektiven Extraktion sind vor allem Hardware-Änderungen denkbar. Im Rahmen der Arbeit wurden erste Tests zur Extraktion von Bauteilen mittels Laser durchgeführt. Hiermit konnten sehr gute Ergebnisse erzielt werden. Die zu extrahierenden Bauteile haben sich mit diesem Laserextraktionsverfahren einschließlich der Löt pads gelöst und konnten anschließend ohne Krafteinwirkung entfernt werden. Auf Basis dieser Tests erscheint ein Lasersystem mit einer optischen Leistung von mehr als 200 Watt ausreichend, um Extraktionen von Bauteilen mit einer Prozesszeit kleiner 2 s zu erlauben. Alternativ könnte auch ein modifizierter Reflow-Ofen verwendet werden, um alle Lötstellen aufzuschmelzen, wobei die hierzu nötige Energie einen relativ großen Anteil an den Gesamtkosten für den laufenden Betrieb einnehmen würde. Die zu extrahierenden Bauteile könnten anschließend mittels Druckluft von der Leiterplatte getrennt werden.

# Anhang

## A.1 Zusammensetzung des untersuchten Elektroschrotts

Die nachfolgende Tabelle A.1 zeigt die durchschnittliche Zusammensetzung verschiedener Fraktionen der untersuchten EAG und wurde in Zusammenarbeit mit Jiayi Wang erstellt [Wan16]. Die im Rahmen der Arbeit verwendeten Leiterplatten sind jedoch nicht komplett enthalten. Zur Datengewinnung wurden die EAG manuell aufgetrennt und die einzelnen Fraktionen mit einer Genauigkeit von 1 g gewogen. Zur Lesbarkeit wurden die einzelnen Fraktionen mit entsprechenden Buchstaben abgekürzt (Q = Quelle, U = Untergruppe, L = Leiterplatte).

| Quelle               | Q1       | Q2      | U1      | U2    | U3      | U4    | L1    | L2    | L3   | L4   | L5    |
|----------------------|----------|---------|---------|-------|---------|-------|-------|-------|------|------|-------|
| <b>Gesamtgewicht</b> | 10,58 kg | 5,48 kg | 6,62 kg | 706 g | 1,67 kg | 503 g | 564 g | 107 g | 67 g | 19 g | 283 g |
| <b>Metall</b>        | -        | 2,63 kg | 5,94 kg | 510 g | 517 g   | 469 g | -     | -     | -    | -    | -     |
| <b>Kunststoff</b>    | -        | 2,17 kg | 445 g   | 135 g | -       | 5 g   | -     | -     | -    | -    | -     |
| <b>Kabel</b>         | -        | 40 g    | 175 g   | -     | 227 g   | -     | -     | -     | -    | -    | -     |
| <b>Leiterplatten</b> | -        | 319 g   | 65 g    | 61 g  | 915 g   | 30 g  | -     | -     | -    | -    | -     |
| <b>Panel</b>         | -        | 446 g   | -       | -     | -       | -     | -     | -     | -    | -    | -     |

**Tabelle A.1:** Durchschnittliche Zusammensetzung verschiedener EAG-Fraktionen.

**Q1:** Desktop-Rechner, Bauhof, 9 Stück

**Q2:** Bildschirme, Hochschule, 11 Stück, 8 Stück mit Gesamtgewicht

**U1:** Gehäuse von Desktop-Rechnern, Hochschule/Bauhof, 11 Stück

**U2:** CD- und Disketten-Laufwerke, div. Quellen, 27 Stück

**U3:** Netzteile, Hochschule/Bauhof, 13 Stück

**U4:** Festplatten, div. Quellen, 11 Stück

**L1:** Mainboards von Desktop-Rechnern, div. Quellen, 24 Stück

**L2:** Grafikkarten von Desktop-Rechnern, div. Quellen, 21 Stück

**L3:** Erweiterungskarten von Desktop-Rechnern, div. Quellen, 25 Stück

**L4:** RAM-Riegel von Desktop-Rechnern, div. Quellen, 22 Stück

**L5:** Mainboards aus Notebooks, lokaler Recyclingbetrieb, 13 Stück, 1 Stück mit Gesamtgewicht

## A.2 Auswertung des Verkaufswerts von Tantalfraktionen

Der wirtschaftliche Wert einer Tantalfraktion setzt sich vor allem aus dem Gesamtgewicht des enthaltenen Tantals sowie dem Grad und der Art der Verunreinigung zusammen. Natürlich spielen auch Geschäftsbeziehungen eine entsprechende Rolle, die hier jedoch vernachlässigt werden sollen. Zur Vereinfachung wird der wirtschaftliche Wert nachfolgend für eine Notebook-Leiterplattenfraktion mit 13 Leiterplatten berechnet, die von einem lokalen Recyclingbetrieb bezogen wurde. Diese Leiterplatten zählen zu der sogenannten “High-grade“-Fraktion mit einem relativ hohen Anteil an Edelmetallen und auch HT-Metallen.

Um das Gesamtgewicht der Tantalfraktion abschätzen zu können, wird zunächst das Gewicht eines durchschnittlichen Tantalkondensators auf Basis der Leiterplattenfraktion berechnet. Dazu wurden die vorkommenden Kondensatoren auf ihre Häufigkeit hin untersucht und in drei Gewichts- bzw. Größengruppen<sup>14</sup> unterteilt. Anschließend wurden für jede Gruppe mehrere Kondensatoren ausgewählt, gewogen und die Gewichte gemittelt. Das durchschnittliche Vorkommen bzw. die Häufigkeit der drei Größengruppen in der Leiterplattenfraktion wurde manuell bestimmt.

Die Kenngrößen der einzelnen Gruppen sind nachfolgend in Tabelle A.2 angegeben. Die Anzahl der Werte, auf denen das jeweilige durchschnittliche Gewicht basiert, ist in Klammern vermerkt. Die Messwerte für Länge, Breite und Höhe basieren auf einem stellvertretenden Kondensator der jeweiligen Gruppe.

|                       | Länge  | Breite | Höhe   | Gewicht     | Vorkommen |
|-----------------------|--------|--------|--------|-------------|-----------|
| <b>große Kond.</b>    | 7,2 mm | 4,5 mm | 3 mm   | 305 mg (27) | 80 %      |
| <b>mittlere Kond.</b> | 6 mm   | 3,3 mm | 2,7 mm | 158 mg (72) | 15 %      |
| <b>kleine Kond.</b>   | 3,7 mm | 2,9 mm | 2 mm   | 72 mg (14)  | 5 %       |

**Tabelle A.2:** Einteilung und Kenngrößen der untersuchten Tantalkondensatoren

Damit wiegt der durchschnittliche Tantalkondensator etwa 271 mg. Insgesamt wurden auf den 13 Leiterplatten 263 unterschiedliche Tantalkondensatoren gezählt. Dadurch ergeben sich etwa 20 Tantalkondensatoren je Leiterplatte mit einem Tantalanteil von insgesamt 2,01 g Tantal je Notebookleiterplatte unter Berücksichtigung des durchschnittlichen Tantalgehalts von 36,7 % [Mar+16, S. 98]. Das Gewicht der Tantalmenge für 1 kg Notebookleiterplatte beträgt somit 7,11 g. Ein Vergleich mit der Literatur zeigt ähnliche Resultate. Oguchi et al. haben auf Basis zweier Notebook-Platinen ein Gewicht von 5,8 g/kg bestimmt [Ogu+11]. Eine Evaluation mit einem kooperierenden Projektteam hat zudem bei einer wesentlich größeren Stichprobe vergleichbare Resultate hinsichtlich der Tantalkondensatoren je Leiterplatte erbracht

<sup>14</sup>Dieses Vorgehen ist nötig, da die Kondensatoren bei dem Test nicht extrahiert werden durften.

[Sau+18]. Untersucht wurden 200 „High-grade“-PCBs mit einem Durchschnittsgewicht von 537,5 g und durchschnittlich 24 Kondensatoren je PCB. Aufgrund des höheren PCB-Gewichts beträgt der Tantalanteil nach Sauer et al. etwa 4,5 g/kg.

Der durchschnittliche Preis für Tantal-Pentoxid, das auch in den Kondensatoren eingesetzt wird, betrug für den Zeitraum von August 2016 bis Juli 2017 etwa 153 €/kg bei einer Reinheit von 99,5 %. Der aktuelle<sup>15</sup> Preis ist leicht gestiegen und liegt bei etwa 189 €/kg. Die Preise sind dem Preismonitor der Deutschen Rohstoffagentur entnommen [Deu17].

Zur Berechnung des wirtschaftlichen Werts des extrahierten Tantals wird aufgrund der Verunreinigung weiterhin eine Preisreduktion um 75 % angenommen. Als Ausgangspreis ergibt sich somit ein Wert von  $153 \text{ €/kg} \times 25 \% = 38,25 \text{ €/kg}$  bei konservativer Schätzung. Darauf aufbauend errechnet sich ein wirtschaftlicher Wert von 0,077 € für das Material auf einer Leiterplatte bzw. 0,0038 € je Tantalkondensator.

---

<sup>15</sup>Stand Juli 2017



# Literatur- und Quellenverzeichnis

- [ABD12] P. F. Alcantarilla, A. Bartoli und A. J. Davison. “KAZE Features”. In: *Europ. Conf. on Computer Vision*. 2012, S. 214–227. DOI: 10.1007/978-3-642-33783-3<sub>16</sub>.
- [Abe05] S. Abe. *Support Vector Machines for Pattern Classification*. Advances in pattern recognition. London: Springer, 2005. ISBN: 9781852339296.
- [All17] Allied Vision Technologies GmbH, Hrsg. *GigE Vision Cameras: Prosilica GT - Technical Manual V2.8.1*. 2017.
- [ANB13] P. F. Alcantarilla, J. Nuevo und A. Bartoli. “Fast Explicit Diffusion for Accelerated Features in Nonlinear Scale Spaces”. In: *British Machine Vision Conf.* 2013.
- [AS15] Allied Vision Technologies GmbH und Stemmer Imaging GmbH, Hrsg. *DataSheet Prosilica GT 2050: v3.0.0 english*. 2015. URL: [https://www.stemmer-imaging.de/media/uploads/cameras/avt/11/113229-Allied\\_Vision\\_Prosilica\\_GT-2050.pdf](https://www.stemmer-imaging.de/media/uploads/cameras/avt/11/113229-Allied_Vision_Prosilica_GT-2050.pdf).
- [Bae14] B. Baesens. *Analytics in a Big Data World: The Essential Guide to Data Science and Its Applications*. Hoboken, USA: John Wiley & Sons, 2014. ISBN: 9781118892701.
- [Bal+15] C. P. Balde, F. Wang, R. Kuehr und J. Huisman. *The Global E-Waste Monitor 2014: Quantities, Flows and Resources*. Bonn: United Nations University, 2015. ISBN: 9789280845563.
- [Beu16] P. Beuth. *Künstliche Intelligenz: Google besiegt erstmals einen Go-Profi*. Hrsg. von Zeit Online. 2016. URL: <http://www.zeit.de/digital/internet/2016-01/kuenstliche-intelligenz-google-deepmind-go-alphago>.
- [Bin+13] K. Binnemans, P. T. Jones, B. Blanpain, T. van Gerven, Y. Yang, A. Walton und M. Buchert. “Recycling of Rare Earths: A Critical Review”. In: *Journal of Cleaner Production*. 51. 2013, S. 1–22. DOI: 10.1016/j.jclepro.2012.12.037.
- [Bis06] C. M. Bishop. *Pattern Recognition and Machine Learning*. Information science and statistics. Springer, 2006. ISBN: 9780387310732.
- [BPF12] J. Beyerer, F. Puente León und C. Frese. *Automatische Sichtprüfung: Grundlagen, Methoden und Praxis der Bildgewinnung und Bildauswertung*. Berlin, Heidelberg: Springer, 2012. ISBN: 9783642239656.

- [Bre+15] M. Breier, P. Möller, W. Li, M. Bosling, T. Pretz und D. Merhof. “Accurate Laser Triangulation Using a Perpendicular Camera Setup to Assess the Height Profile of PCBs”. In: *Int. Conf. on Industrial Technology*. 2015, S. 1613–1618. DOI: 10.1109/ICIT.2015.7125327.
- [Bre+16] M. Breier, P. Küsters, A. König, W. Li, M. Bosling, T. Pretz und D. Merhof. “Rectification for Fronto-parallel Camera Movement in 3D Reconstruction of Printed Circuit Boards”. In: *Int. Conf. on Instrumentation and Measurement Technology*. 2016. DOI: 10.1109/I2MTC.2016.7520359.
- [Bre01] L. Breiman. “Random Forests”. In: *Machine Learning*. 45(1). Kluwer Academic Publishers, 2001, S. 5–32. DOI: 10.1023/A:1010933404324.
- [Bre96] L. Breiman. “Bagging Predictors”. In: *Machine Learning*. 24(2). Kluwer Academic Publishers, 1996, S. 123–140. DOI: 10.1007/BF00058655.
- [Bun12] Bundesministerium für Bildung und Forschung, Hrsg. *Wirtschaftsstrategische Rohstoffe für den Hightech-Standort Deutschland: Forschungs- und Entwicklungsprogramm des BMBF für neue Rohstofftechnologien*. 2012.
- [Cha+02] N. V. Chawla, K. W. Bowyer, L. O. Hall und W. P. Kegelmeyer. “SMOTE: Synthetic Minority Over-sampling Technique”. In: *Journal of Artificial Intelligence Research*. 16. 2002, S. 321–357. DOI: 10.1613/jair.953.
- [CL14] J. Cleve und U. Lämmel. *Data Mining*. München: Oldenbourg Wissenschaftsverlag, 2014. ISBN: 9783486720341.
- [Coh60] J. Cohen. “A Coefficient of Agreement for Nominal Scales”. In: *Educational Psychology Measurement*. Bd. 20(1). 1960, S. 37–46. DOI: 10.1177/001316446002000104.
- [Cor+16] M. Cordts, M. Omran, S. Ramos, T. Rehfeld, M. Enzweiler, R. Benenson, U. Franke, S. Roth und B. Schiele. “The Cityscapes Dataset for Semantic Urban Scene Understanding”. In: *Int. Conf. on Computer Vision and Pattern Recognition*. 2016, S. 3213–3223. DOI: 10.1109/CVPR.2016.350.
- [Dav05] E. R. Davies. *Machine Vision: Theory, Algorithms, Practicalities*. 3. Aufl. San Francisco, USA: Morgan Kaufmann Publishers, 2005. ISBN: 012206-0938.
- [Deu17] Deutsche Rohstoffagentur, Bundesanstalt für Geowissenschaften und Rohstoffe, Hrsg. *DERA Preismonitor*. 2017. URL: [https://www.deutsche-rohstoffagentur.de/DERA/DE/Rohstoffinformationen/Rohstoffpreise/Preismonitor/preismonitor\\_node.html](https://www.deutsche-rohstoffagentur.de/DERA/DE/Rohstoffinformationen/Rohstoffpreise/Preismonitor/preismonitor_node.html).
- [Dom12] P. Domingos. “A Few Useful Things to Know About Machine Learning”. In: *Communications of the Association for Computing Machinery*. 55(10). 2012, S. 78–87. DOI: 10.1145/2347736.2347755.

- [DT05] N. Dalal und B. Triggs. “Histograms of Oriented Gradients for Human Detection”. In: *Int. Conf. on Computer Vision and Pattern Recognition*. 2005, S. 886–893. DOI: 10.1109/CVPR.2005.177.
- [Eng97] K. Englert. “Anlagen sowie Verfahren zur Automatischen Entstückung”. EP0671118 B1. 1997. URL: <http://www.google.com/patents/EP0671118B1?cl=de>.
- [Faw06] T. Fawcett. “An Introduction to ROC Analysis”. In: *Pattern Recognition Letters*. 27(8). 2006, S. 861–874. DOI: 10.1016/j.patrec.2005.10.010.
- [Gir+14] R. Girshick, J. Donahue, T. Darrell und J. Malik. “Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation”. In: *Conf. on Computer Vision and Pattern Recognition*. 2014, S. 580–587. DOI: 10.1109/CVPR.2014.81.
- [GL12] J. Gu und C. Liu. “Discriminative Illumination: Per-Pixel Classification of Raw Materials Based on Optimal Projections of Spectral BRDF”. In: *Int. Conf. on Computer Vision and Pattern Recognition*. 2012, S. 797–804. DOI: 10.1109/CVPR.2012.6247751.
- [GNS07] P. Gramatyka, R. Nowosielski und P. Sakiewicz. “Recycling of Waste Electrical and Electronic Equipment”. In: *Journal of Achievements in Materials and Manufacturing Engineering*. 20(1-2). 2007, S. 535–538.
- [Gra+11] T. E. Graedel, J. Allwood, J.-P. Birat, M. Buchert, C. Hagelüken, B. K. Reck, S. F. Sibley und G. Sonnemann. *Recycling Rates of Metals: A Status Report*. Nairobi, Kenya: United Nations Environment Programme, 2011. ISBN: 9789280731613.
- [HLB13] D. Herchenbach, W. Li und M. Breier. “Segmentation and Classification of THCs on PCBAs”. In: *11th Int. Conf. on Industrial Informatics*. 2013, S. 59–64. DOI: 10.1109/INDIN.2013.6622858.
- [Hor06] A. Hornberg, Hrsg. *Handbook of Machine Vision*. Weinheim: WILEY-VCH, 2006. ISBN: 9783527405848.
- [HWN01] G. Hanreich, K. J. Wolter und J. Nicolics. “Rework of Flip-Chip Populated PCBs by Laser Desoldering”. In: *24th Int. Spring Seminar on Electronics Technology*. 2001, S. 63–67. DOI: 10.1109/ISSE.2001.931013.
- [HZ04] R. Hartley und A. Zisserman. *Multiple View Geometry in Computer Vision*. 2. Aufl. Cambridge, UK: Cambridge University Press, 2004. ISBN: 9780521540513.
- [Kel08] E. J. Kelley. In: *Printed Circuits Handbook*. Hrsg. von C. F. Coombs Jr. McGraw-Hill handbooks. New York, USA: McGraw-Hill, 2008, Kapitel 6–11. ISBN: 0071510796.
- [KK15a] F. Kleber und M. Kampel. “Pre-Analysis of Printed Circuit Boards Based On Multispectral Imaging for Vision Based Recognition of Electronics Waste”. In: *Int. Journal of Computer, Electrical, Automation, Control and Information Engineering*. 9(3). 2015, S. 656–660.

- [KK15b] B. Kopacek und P. Kopacek. “Extracting Rare Materials from Electr(on)ic Scrap”. In: *Int. Federation of Automatic Control - Papers On Line*. 48(24). 2015, S. 157–161. DOI: 10.1016/j.ifacol.2015.12.075.
- [Kle+15] F. Kleber, C. Pramerdorfer, E. Wetzinger und M. Kampel. “Optical Sensor Evaluation for Vision Based Recognition of Electronics Waste”. In: *Int. Journal of Environmental Science and Development*. 6(12). 2015, S. 929–933. DOI: 10.7763/IJESD.2015.V6.724.
- [Kno+01] R. Knoth, M. Hoffmann, B. Kopacek und P. Kopacek. “Intelligent Disassembly of Electr(on)ic Equipment”. In: *Second Int. Symp. on Environmentally Conscious Design and Inverse Manufacturing*. 2001, S. 557–561. DOI: 10.1109/.2001.992423.
- [Kop07] P. Kopacek. “Intelligent Assembly and Disassembly Past, Present and Future”. In: *Int. Federation of Automatic Control Proceedings Volumes*. 40(2). 2007, S. 1–7. DOI: 10.3182/20070523-3-ES-4907.00003.
- [Kop16] B. Kopacek. “Intelligent Disassembly of Components from Printed Circuit Boards to Enable Re-use and more Efficient Recovery of Critical Metals”. In: *Electronics Goes Green 2016+*. 2016, S. 1–8. DOI: 10.1109/EGG.2016.7829842.
- [Kru+15] R. Kruse, C. Borgelt, C. Braune, F. Klawonn, C. Möwes und M. Steinbrecher. *Computational Intelligence: Eine methodische Einführung in Künstliche Neuronale Netze, Evolutionäre Algorithmen, Fuzzy-Systeme und Bayes-Netze*. 2. Aufl. SpringerLink: Bücher. Wiesbaden: Springer, 2015. ISBN: 9783658109042.
- [KSH12] A. Krizhevsky, I. Sutskever und G. E. Hinton. “ImageNet Classification with Deep Convolutional Neural Networks”. In: *Advances in Neural Information Processing Systems*. 25. 2012, S. 1097–1105.
- [LB95] Y. LeCun und Y. Bengio. “Convolutional Networks for Images, Speech, and Time-Series”. In: *The Handbook of Brain Theory and Neural Networks*. Hrsg. von M. A. Arbib. Cambridge, USA: The MIT Press, 1995, S. 276–279. ISBN: 9780262011976.
- [LEB13] W. Li, B. Esders und M. Breier. “SMD Segmentation for Automated PCB Recycling”. In: *11th Int. Conf. on Industrial Informatics*. 2013, S. 65–70. DOI: 10.1109/INDIN.2013.6622859.
- [LYG13] C. Liu, G. Yang und J. Gu. “Learning Discriminative Illumination and Filters for Raw Material Classification with Optimal Projections of Bi-directional Texture Functions”. In: *Int. Conf. on Computer Vision and Pattern Recognition*. 2013, S. 1430–1437. DOI: 10.1109/CVPR.2013.188.
- [Mar+16] F. Marscheider-Weidemann, S. Langkau, T. Hummen, L. Erdmann, L. A. Tercero Espinoza, G. Angerer, M. Marwede und S. Benecke. *Rohstoffe für Zukunftstechnologien 2016: DERA Rohstoffinformationen 28*. Berlin, 2016. ISBN: 9783943566710.

- [Mel13] M. Meloni. “Removing and Segregating Components from Printed Circuit Boards”. US 20130125364 A1. 2013. URL: <https://www.google.ch/patents/US20130125364>.
- [Mel14] F. Melcher. “Kritische Hochtechnologiemetalle – Verfügbarkeit in der EU mit Fokus auf Österreich”. In: *Berg- und Hüttenmännische Monatshefte*. 159(10). 2014, S. 406–410. DOI: 10.1007/s00501-014-0307-4.
- [MP43] W. S. McCulloch und W. Pitts. “A Logical Calculus of the Ideas Immanent in Nervous Activity”. In: *Bulletin of Mathematical Biophysics*. 5(4). 1943, S. 115–133. DOI: 10.1007/BF02478259.
- [Ogu+11] M. Oguchi, S. Murakami, H. Sakanakura, A. Kida und T. Kameya. “A Preliminary Categorization of End-of-life Electrical and Electronic Equipment as Secondary Metal Resources”. In: *Waste Management*. 31(9-10). 2011, S. 2150–2160. DOI: 10.1016/j.wasman.2011.05.009.
- [OPH94] T. Ojala, M. Pietikainen und D. Harwood. “Performance Evaluation of Texture Measures with Classification Based on Kullback Discrimination of Distributions”. In: *12th Int. Conf. on Pattern Recognition*. 1994, S. 582–585. DOI: 10.1109/ICPR.1994.576366.
- [PD12] M. Polák und L. Drápalová. “Estimation of End of Life Mobile Phones Generation: The Case Study of the Czech Republic”. In: *Waste Management*. 32(8). 2012, S. 1583–1591. DOI: 10.1016/j.wasman.2012.03.028.
- [PK15] C. Pramerdorfer und M. Kampel. “A Dataset for Computer-Vision-Based PCB Analysis”. In: *14th Int. Conf. on Machine Vision Applications*. 2015, S. 378–381. DOI: 10.1109/MVA.2015.7153209.
- [PMC11] M. Peemen, B. Mesman und H. Corporaal. “Speed Sign Detection and Recognition by Convolutional Neural Networks”. In: *8th Int. Automotive Congress*. 2011, S. 162–170.
- [Pra+16] S. Prakash, G. Dehoust, M. Gsell, T. Schleicher und R. Stamminger. *Einfluss der Nutzungsdauer von Produkten auf ihre Umweltwirkung: Schaffung einer Informationsgrundlage und Entwicklung von Strategien gegen Obsoleszenz*. Texte 11/2016, ISSN 1862-4804. Dessau-Roßlau: Umweltbundesamt, 2016.
- [Pra01] W. K. Pratt. *Digital Image Processing: PIKS Inside*. 3. Aufl. New York, USA: John Wiley & Sons, 2001. ISBN: 0471374075.
- [Qui86] J. R. Quinlan. “Induction of Decision Trees”. In: *Machine Learning*. 1. 1986, S. 81–106.
- [Qui92] J. R. Quinlan. *C4.5: Programs for Machine Learning*. The Morgan Kaufmann Series in Machine Learning. San Mateo, USA: Morgan Kaufmann Publishers, 1992. ISBN: 9781558602397.
- [Roj96] R. Rojas. *Theorie der neuronalen Netze: Eine systematische Einführung*. 4. Aufl. Springer-Lehrbuch. Berlin, Heidelberg: Springer, 1996. ISBN: 3540563539.

- [Ros58] F. Rosenblatt. “The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain”. In: *Psychological Review*. 65(6). 1958, S. 386–408. DOI: 10.1037/h0042519.
- [SBK14] Y. Schockert, M. Berwanger und M. Koester. “Sensor-Based Tantalum Identification”. In: *Sensor Technologies*. Hrsg. von K. Nienhaus, T. Pretz und H. Wotruba. Schriftenreihe zur Aufbereitung und Veredlung. Herzogenrath: Shaker, 2014, S. 378–392. ISBN: 9783844025637.
- [Sch15] J. Schmidhuber. *Recurrent Neural Networks*. 2015. URL: <http://people.idsia.ch/~juergen/rnn.html>.
- [Sha48] C. E. Shannon. “A Mathematical Theory of Communication”. In: *The Bell System Technical Journal*. 27. 1948, S. 379–423, 623–656.
- [SS02] B. Schölkopf und A. J. Smola. *Learning with Kernels: Support Vector Machines, Regularization, Optimization and Beyond*. Adaptive Computation and Machine Learning. Cambridge, Mass. und London: The MIT Press, 2002. ISBN: 0262194759.
- [Sta04] Statistisches Bundesamt, Hrsg. *Informationstechnologie in Haushalten: Tabellenanhang zur Pressebroschüre*. 2004. URL: <https://www.destatis.de/DE/Publikationen/Thematisch/EinkommenKonsumLebensbedingungen/PrivateHaushalte/InformationstechnologieHaushalte.html>.
- [Sta16] Statistisches Bundesamt, Hrsg. *Wirtschaftsrechnungen: Private Haushalte in der Informationsgesellschaft - Nutzung von Informations- und Kommunikationstechnologien: Fachserie 15 Reihe 4*. Wiesbaden, 2016. URL: <https://www.destatis.de/DE/Publikationen/Thematisch/EinkommenKonsumLebensbedingungen/PrivateHaushalte/PrivateHaushalteIKT.html>.
- [Stö16] C. Stöcker. *Software-Sieg im Brettspiel: Es geht um weit mehr als Go*. 2016. URL: <http://www.spiegel.de/netzwelt/gadgets/alphago-sieg-wendepunkt-der-menschheitsgeschichte-a-1082001.html>.
- [Sze11] R. Szeliski. *Computer Vision: Algorithms and Applications*. Texts in Computer Science. London und New York: Springer, 2011. ISBN: 9781848829343.
- [TZ00] P. H. S. Torr und A. Zisserman. “MLE-SAC: A New Robust Estimator with Application to Estimating Image Geometry”. In: *Computer Vision and Image Understanding*. 78(1). 2000, S. 138–156. DOI: 10.1006/cviu.1999.0832.
- [Uij+13] J. R. R. Uijlings, K. E. A. Van De Sande, T. Gevers und A. W. M. Smeulders. “Selective Search for Object Recognition”. In: *Int. Journal of Computer Vision*. 104(2). 2013, S. 154–171. DOI: 10.1007/s11263-013-0620-5.

- [vE16] A. B. van Wyk und A. P. Engelbrecht. “Analysis of Activation Functions for Particle Swarm Optimised Feedforward Neural Networks”. In: *Congress on Evolutionary Computation*. 2016, S. 423–430. DOI: 10.1109/CEC.2016.7743825.
- [vR96] E. R. van Dop und P. P. L. Regtien. “Volumetric Segmentation of Range Images for Printed Circuit Board Inspection”. In: *Automated Optical Inspection for Industry*. 2899. 1996, S. 687–694. DOI: 10.1117/12.252997.
- [Wit+16] I. H. Witten, E. Frank, M. A. Hall und C. J. Pal. *The WEKA Workbench: Online Appendix for "Data Mining: Practical Machine Learning Tools and Techniques"*. 4. Aufl. Morgan Kaufmann Publisher, 2016.
- [Yua+07] C. Y. Yuan, H. C. Zhang, G. McKenna, C. Korzeniewski und J. Li. “Experimental Studies on Cryogenic Recycling of Printed Circuit Board”. In: *Int. Journal of Advanced Manufacturing Technology*. 34(7-8). 2007, S. 657–666. DOI: 10.1007/s00170-006-0634-z.
- [Zha00] Z. Zhang. “A Flexible New Technique for Camera Calibration”. In: *Trans. on Pattern Analysis and Machine Intelligence*. 22(11). 2000, S. 1330–1334. DOI: 10.1109/34.888718.



# Veröffentlichungen des Autors

## Journal-Veröffentlichungen

- [Sau+18] F. Sauer, J. Ruecker, G. Beck, U. Bochtler und T. Maier. “Disassembly of Tantalum Capacitors from Waste PCBs”. In: *Resources, Conservation and Recycling*. Hrsg. von M. Xu. 2018, (geplant).

## Konferenzbeiträge

- [Rue+16a] J. Ruecker, H.-X. Hesch, U. Bochtler und P. J. Klar. “An Empirical Approach for More Effective Recycling of Electronic Components in WEEE”. In: *7th Sensor-Based Sorting & Control 2016*. Hrsg. von T. Pretz und H. Wotruba. Herzogenrath: Shaker, 2016, S. 249–258. ISBN: 9783844043235.
- [Rue+16b] J. Ruecker, H.-X. Hesch, U. Bochtler und P. J. Klar. “Automated Segmentation of Electronic Components on Waste Printed Circuit Boards”. In: *7th Sensor-Based Sorting & Control 2016*. Hrsg. von T. Pretz und H. Wotruba. Herzogenrath: Shaker, 2016, S. 179–185. ISBN: 9783844043235.
- [Rue+16c] J. Ruecker, C. Kohlbrenner, M. Ziemer, U. Bochtler und P. J. Klar. “Classification of Electronic Components based on multispectral Bidirectional Reflectance Distribution Function (BRDF)”. In: *Kleinheubacher Tagung 2016*. Hrsg. von U.R.S.I. Landesausschuss in der Bundesrepublik Deutschland e.V. 2016.
- [Rue+17a] J. Ruecker, P. Peper, U. Bochtler und P. J. Klar. “Optical identification of valuable materials on printed circuit board assemblies based on sensor fusion”. In: *OCM 2017 - 3rd International Conference on Optical Characterization of Materials*. Hrsg. von J. Beyerer, F. Puente León und T. Längle. Karlsruhe: KIT Scientific Publishing, 2017, S. 43–51. ISBN: 978-3-7315-0612-6.
- [Rue+17b] J. Ruecker, P. Peper, M. Kern, M. Ziemer, U. Bochtler und P. J. Klar. “Qualitative Comparison of Supervised Learning Methods for the Classification of Electronic Components on PCBAs”. In: *Proceedings of AC 2017 in Prague*. 2017, S. 80–88. ISBN: 978-80-88085-15-7.

- [Rue+17c] J. Ruecker, M. Ziemer, P. Peper, U. Bochtler und P. J. Klar. “Entwicklung eines neuartigen Recyclingverfahrens für Komponenten elektrischer Altgeräte”. In: *Jahrestreffen der ProcessNet Fachgruppen Energieverfahrenstechnik und Abfallbehandlung und Wertstoffrückgewinnung*. Hrsg. von DECHEMA e.V. 2017.
- [Wan+16] J. Wang, J. Ruecker, H.-X. Hesch, U. Bochtler und P. J. Klar. “Analyse von elektronischen Altgeräten im Hinblick auf verbesserte Recyclingverfahren”. In: *Jahrestreffen der ProcessNet Fachgruppen Energieverfahrenstechnik und Abfallbehandlung und Wertstoffrückgewinnung*. Hrsg. von DECHEMA e.V. 2016.

## **Beträge in Fachzeitschriften**

- [Rue+15] J. Ruecker, H.-X. Hesch, U. Bochtler und P. J. Klar. “Automatische Entstückung von Leiterplatten zur Rückgewinnung von Ressourcen”. In: *PLUS Band 12*. Bad Saulgau: Leuze-Verlag, 2015.

# Betreute Arbeiten

- [Hes15] H.-X. Hesch. *Ressourcenpotentiale, Sortierkriterien und Energieeffiziente Aufbereitungsverfahren für elektronische Altgeräte (EAG)*. Masterarbeit, Hochschule Aschaffenburg, 2015.
- [Ker18] M. Kern. *Evaluierung der großtechnischen Umsetzung und Energiebedarfsanalyse einer neuartigen Entstückungsanlage*. Masterarbeit (geplant), Hochschule Aschaffenburg, 2018.
- [Koh16] C. Kohlbrenner. *Bauteilidentifikation auf Basis der bidirektionalen Reflexions-Verteilungsfunktion*. Bachelorarbeit, Hochschule Aschaffenburg, 2016.
- [Pep17] P. Peper. *Evaluierung bildgebender Verfahren zur Klassifikation wertstoffreicher Elektronikkomponenten unter Berücksichtigung der Echtzeitfähigkeit*. Masterarbeit, Hochschule Aschaffenburg, 2017.
- [Wan16] J. Wang. *Elektroschrottanalyse zur Entwicklung einer robotergestützten Entstückung*. Bachelorarbeit, Hochschule Aschaffenburg, 2016.
- [Zie17] M. Ziemer. *Evaluierung universeller Entstückungsautomaten zur Wiederaufbereitung elektrischer und elektronischer Altgeräte*. Masterarbeit, Hochschule Aschaffenburg, 2017.



# Abbildungsverzeichnis

|      |  |    |
|------|--|----|
| 1.1  | Vergleichende Darstellung unterschiedlicher Leiterplatten . . . . .            | 4  |
| 2.1  | Aufbau eines typischen Bildverarbeitungssystems . . . . .                      | 10 |
| 2.2  | Darstellung des Funktionsprinzips eines Laserscanners . . . . .                | 11 |
| 2.3  | Moiré-Effekt an einem elektronischen Bauteil . . . . .                         | 13 |
| 2.4  | Darstellung von Verzeichnungen . . . . .                                       | 16 |
| 2.5  | Veranschaulichung von Erosion und Dilatation . . . . .                         | 17 |
| 2.6  | Darstellung einer BLOB-Detektion . . . . .                                     | 18 |
| 2.7  | Verschiedene Definitionen von „zusammenhängend“ für BLOBs . . . . .            | 18 |
| 2.8  | Bestimmung einer Geraden mittels RANSAC . . . . .                              | 19 |
| 2.9  | Streuung unterschiedlicher Merkmalswerte . . . . .                             | 21 |
| 2.10 | Veranschaulichung von Hauptkomponenten . . . . .                               | 22 |
| 2.11 | Mögliche Trennebenen für linear separable Datenpunkte . . . . .                | 26 |
| 2.12 | Optimale und suboptimale Trennebene . . . . .                                  | 26 |
| 2.13 | Transformation mittels Kernelfunktion . . . . .                                | 29 |
| 2.14 | Prinzipien zum Lösen von Mehrklassenproblemen . . . . .                        | 29 |
| 2.15 | Darstellung eines künstlichen Neurons . . . . .                                | 30 |
| 2.16 | Darstellung eines KNN mit 3 Knoten . . . . .                                   | 31 |
| 2.17 | Aufbau eines KNN mit mehreren Schichten . . . . .                              | 32 |
| 2.18 | Vergleich von Aktivierungsfunktionen . . . . .                                 | 33 |
| 2.19 | Darstellung eines beliebigen CNNs . . . . .                                    | 35 |
| 2.20 | Entscheidungsbaum für das Sportereignisproblem . . . . .                       | 38 |
| 2.21 | Beispielhafte ROC-Kurven . . . . .   | 40 |
| 3.1  | Resultat der manuellen Markierung von Leiterplatten . . . . .                  | 45 |
| 4.1  | Konzeption der Anlage . . . . .  | 48 |
| 4.2  | Aufbau zur Detektion . . . . .   | 48 |
| 4.3  | Spektrale Empfindlichkeit der eingesetzten Kamera . . . . .                    | 49 |
| 4.4  | Funktionsweise der aufgebauten Beleuchtungseinheit . . . . .                   | 50 |
| 4.5  | Veranschaulichung der Interpolation der Höhenmesswerte . . . . .               | 51 |
| 4.6  | Beispiel für eine korrekte und eine fehlerhafte Kalibration . . . . .          | 51 |
| 4.7  | Durch die Spektroskopiehalbkugel abgedeckte Wellenlängenbereiche . . . . .     | 52 |
| 5.1  | Darstellung des Synchronisationsobjekts als Höhenprofil und Farbbild . . . . . | 54 |
| 5.2  | Verdeutlichung der zeitlichen Synchronisation . . . . .                        | 55 |
| 5.3  | Veranschaulichung der räumlichen Synchronisation mittels Zuschnitt . . . . .   | 55 |
| 5.4  | BLOB-Detektion einzelner Platinen . . . . .                                    | 56 |

|      |   |    |
|------|---|----|
| 5.5  | Erzielte Segmentierung durch das RANSAC-Verfahren . . . . .         | 57 |
| 5.6  | Konventionelle und modifizierte Erosion . . . . .                   | 57 |
| 5.7  | BLOB-Detektion der Bauteile . . . . .                               | 58 |
| 5.8  | Flächen-Histogramm segmentierter Komponenten und Referenzdaten      | 60 |
| 5.9  | Darstellung der prozentualen Vergrößerung zur erweiterten Erfassung | 62 |
| 5.10 | Architektur des entworfenen CNNs . . . . .                          | 66 |
| 5.11 | Klassifikationsergebnis des CNNs für eine Testplatine . . . . .     | 67 |
| 6.1  | Kompletter Aufbau zur Extraktion der Bauteile . . . . .             | 74 |
| 6.2  | Darstellung der Delaminierung von Tantalkondensatoren . . . . .     | 76 |
| 6.3  | Entwickeltes Werkzeug zur automatischen Bauteilextraktion . . . . . | 77 |
| 6.4  | Darstellung des Ablaufs zur Extraktion einzelner Bauteile . . . . . | 78 |
| 6.5  | Problematische Umgebung eines Tantalkondensators . . . . .          | 78 |
| 6.6  | Leiterplattenset zur Evaluierung der Extraktion . . . . .           | 79 |

# Tabellenverzeichnis

|      |  |    |
|------|--|----|
| 2.1  | Vergleich ausgewählter bildgebender Verfahren . . . . .                          | 12 |
| 2.2  | Adjazenzmatrix . . . . .   | 31 |
| 2.3  | Daten früherer Sportereignisse . . . . .   | 37 |
| 2.4  | Beispielhafte Wahrheitsmatrix für drei Klassen . . . . .                         | 39 |
| 3.1  | Zusammensetzung des untersuchten Elektroschrotts . . . . .                       | 43 |
| 3.2  | Aufschlüsselung der Leiterplattenbauteile in Klassen . . . . .                   | 44 |
| 4.1  | Einfallswinkel der eingesetzten LED-Cluster . . . . .                            | 52 |
| 5.1  | Untersuchte Morphologieparameter . . . . .                                       | 59 |
| 5.2  | Übereinstimmung segmentierter Komponenten mit den Referenzdaten . . . . .        | 59 |
| 5.3  | Zusammensetzung der reduzierten Untermenge . . . . .                             | 60 |
| 5.4  | Getestete Merkmale . . . . .   | 61 |
| 5.5  | Zusammensetzung des GFSK-Merkmalsvektors . . . . .                               | 61 |
| 5.6  | Variierte Parameter bei der Untersuchung verschiedener Merkmale . . . . .        | 63 |
| 5.7  | Gesamterkennungsraten der getesteten Merkmale . . . . .                          | 64 |
| 5.8  | Wahrheitsmatrizen der getesteten Merkmale . . . . .                              | 65 |
| 5.9  | Parametrierungen der getesteten Klassifikatoren . . . . .                        | 66 |
| 5.10 | Ausgewertete Kenngrößen zur Bewertung der Klassifikatoren . . . . .              | 68 |
| 5.11 | Wahrheitsmatrizen verschiedener Klassifikatoren . . . . .                        | 68 |
| 5.12 | Anzahl der Instanzen pro Klasse . . . . .  | 69 |
| 5.13 | Wahrheitsmatrix des RF in Kombination mit SMOTE . . . . .                        | 70 |
| 5.14 | Durchschnittliche Ausführungszeiten der einzelnen Softwaremodule . . . . .       | 70 |
| 6.1  | Aufzählung verschiedener Verfahren zur Bauteilextraktion . . . . .               | 75 |
| 6.2  | Evaluierung der Tantalextraktion durch Heißluft und Absaugung . . . . .          | 80 |
| 6.3  | Evaluierung der Extraktion von ICs . . . . .                                     | 80 |
| 6.4  | Energiebedarf zur Bearbeitung einer Leiterplatte mit dem Prototyp . . . . .      | 82 |
| 6.5  | Energiebedarf zur Bearbeitung einer Leiterplatte mit Laserdelamination . . . . . | 84 |
| 6.6  | Abschätzung der Systemkosten . . . . .   | 85 |
| A.1  | Zusammensetzung des untersuchten Elektroschrotts . . . . .                       | 91 |
| A.2  | Einteilung und Kenngrößen der untersuchten Tantalkondensatoren . . . . .         | 92 |



# Danksagung

An dieser Stelle möchte ich allen Personen danken, die mich bei der Erstellung dieser Arbeit unterstützt haben. Zuallererst möchte ich mich bei meinem Doktorvater Prof. Dr. Peter Klar bedanken, insbesondere für dessen fachliche Betreuung, konkrete Hilfestellungen und auch für die Geduld bei den vielen Fragen, die sich bei der Erstellung dieser Arbeit als externer Doktorand ergeben haben. Nicht minder möchte ich mich bei meinem direkten Betreuer Prof. Dr.-Ing. Ulrich Bochtler für dessen langjährige fachliche und persönliche Unterstützung bedanken, auf die ich mich jederzeit verlassen konnte und immer noch kann. Dankbar bin ich auch meinen Mitstreitern im Elektroschrottrecycling Heinz-Xaver Hesch, Maximilian Kern, Christian Kohlbrenner, Sarah Levy, Patrick Peper, Jiayi Wang und Marco Ziemer für die kontinuierlichen fachlichen und persönlichen Gespräche, Anregungen, Diskussionen und Hilfestellungen bei dem gemeinsamen Aufbau der Pilotanlage. Um den Recycling-Sektor besser zu verstehen, haben mir außerdem zahlreiche Gespräche mit dem Team des IWKS Alzenau sehr geholfen. Insbesondere bin ich Prof. Dr. Gesa Beck, Florian Sauer, Dr. Gert Homm und Dr. Thorsten Hartfeil für die fachliche Unterstützung und den regelmäßigen Austausch zum Dank verpflichtet. Ferner danke ich als externes Mitglied im Graduiertenkolleg 2204 sowohl der JLU Gießen als auch der DFG für die zur Verfügung gestellten Mittel und die sehr hilfreichen Workshops. Für den freundschaftlichen Umgang und den wissenschaftlichen Diskurs bin ich allen GRK-Mitgliedern sehr dankbar. Besonders dankbar bin ich Dr. Martin Güngerich für seine vielen Hilfestellungen in Bezug auf das GRK 2204. Für die Möglichkeit zur Durchführung von Röntgentests und die damit verbundene fachliche Unterstützung danke ich Prof. Dr. Michael Kaloudis und Miriam Rauer sehr. Mein Dank gebührt auch Prof. Ralf Hellmann, Benedikt Adelman, Simon Schwarz, Stefan Rung und Jürgen Knöll für die Möglichkeit zur gemeinsamen Durchführung von Lasertests und die fachliche Unterstützung. Aus meiner ehemaligen Arbeitsgruppe bin ich außerdem Prof. Dr.-Ing. Konrad Doll, Sebastian Köhler und Michael Hahnle für die fachliche Unterstützung im Bereich Computer Vision und die zur Verfügung gestellte TOF-Kamera sehr dankbar. Darüber hinaus bedanke ich mich bei dem gesamten Laborteam des Schaltungstechniklabors für die schöne Zeit, die regelmäßigen bayerischen Weißwurstfrühstücke und den freundschaftlichen Umgang miteinander. Besonders bedanken möchte ich mich bei Florian Beck und Armin Huth für die Hilfestellung bei dem Bewältigen der vielen Formulare während der letzten 4 Jahre. Meinem Großvater danke ich für die zahllosen Fachdiskussionen und die vielen gemeinsamen Stunden in der Werkstatt. Außerdem möchte ich mich besonders bei meiner Mutter bedanken, die mich während meines gesamten Studiums unterstützt und mir den nötigen Rückhalt gegeben hat. Zuletzt danke ich von ganzem Herzen meiner Partnerin für ihre unermüdliche Unterstützung, ihre Liebe und Motivation.



# Eidesstattliche Erklärung

Ich erkläre: Ich habe die vorgelegte Dissertation selbstständig und ohne unerlaubte fremde Hilfe und nur mit den Hilfen angefertigt, die ich in der Dissertation angegeben habe. Alle Textstellen, die wörtlich oder sinngemäß aus veröffentlichten Schriften entnommen sind, und alle Angaben, die auf mündlichen Auskünften beruhen, sind als solche kenntlich gemacht. Bei den von mir durchgeführten und in der Dissertation erwähnten Untersuchungen habe ich die Grundsätze guter wissenschaftlicher Praxis, wie sie in der „Satzung der Justus-Liebig-Universität Gießen zur Sicherung guter wissenschaftlicher Praxis“ niedergelegt sind, eingehalten.

Aschaffenburg, im September 2017

Johannes Rücker