

Oberflächeninspektion für das roboterbasierte Schleifen: Analytische Methoden vs. Machine Learning

J. Monnet und Ch. Brecher, IPT Aachen

1 Motivation

Das Schleifen von Werkstücken und Bauteilen stellt einen wesentlichen Prozessschritt zur Herstellung vieler Produkte dar. Die Nachbearbeitung von Gussteilen, das Verputzen von Schweißnähten, die Vorbereitung von Beschichtungsprozessen oder auch das Polieren von Kratzern auf Oberflächen sind typische Beispiele solcher Bearbeitungsaufgaben [1–3]. Während solche Aufgaben in der Automobil- oder Luftfahrtindustrie im Bereich der Serienfertigung vermehrt von Robotern übernommen werden [4–6], werden sie in vielen fertigenden KMU noch manuell durchgeführt. Oftmals handelt es sich bei diesen Tätigkeiten um stark repetitive Prozesse, welche je nach aufzubringenden Kräften körperlich sehr anstrengend und bei schwer zugänglichen Bearbeitungsstellen durch das Einnehmen von Zwangshaltungen ergonomisch belastend sind. Je nach Material entstehen potenziell gesundheitsgefährdende Schleifstäube, die das Arbeiten mit Maske erforderlich machen [7].

Die Potenziale eines roboterbasierten Prozesses liegen dabei neben der Entlastung von Werkenden vor allem auch in der Steigerung der Prozesseffizienz sowie in der Erzielung eines konsistenten, hochqualitativen Ergebnisses. Im Hinblick auf den zunehmend stärker werdenden, internationalen Wettbewerbsdruck [8] sowie den allgemeinen Fachkräftemangel, der sich auch im Metallbau manifestiert [9], ist die Erforschung dieser Potenziale als relevant einzustufen. Darüber hinaus führt der allgemeine Trend hin zu einer ressourcen- und klimaschonenden Kreislaufwirtschaft zu einem wachsenden Bedarf nach wiederaufbereiteten Produkten. Neben anderen Technologien haben auch Schleiftechnologien eine hohe Bedeutung, um z.B. eine entsprechende Oberflächengüte wiederherzustellen [10].

Ursachen für die fehlende Automatisierung durch die Nutzung von Robotik sind vielfältig und werden in [11] zusammengefasst. Zunächst einmal erfordern viele Bauteile eine Inspektion, auf dessen Basis eine Entscheidung über den weiteren Bearbeitungsprozess getroffen werden soll. Dies kann, je nach Anwendungsfall die Makrogeometrie von Halbzeugen, aber auch die Mikrogeometrie von Werkstücken, betreffen, die entsprechend ihrer Beschaffenheit individuell nachbearbeitet werden müssen. Der Prozess der Nachbearbeitung erfolgt in einem manuellen Prozess iterativ und intuitiv auf Basis des Erfahrungswissens der Fachkraft. In einem automatisierten System muss dieses Erfahrungswissen in Prozessparameter wie Anpressdruck oder Vorschubgeschwindigkeit und entsprechende Werkzeugpfade überführt werden.

Die flexible Automatisierung von Oberflächenbearbeitungsprozessen lässt sich anhand des grundlegenden Ansatzes der intelligenten Steuerung der Robotik, dem Sense-Plan-Act-Paradigma [12] beschreiben. Somit ist die Oberflächeninspektion in der Sense-Phase Grundlage für die Entscheidung über die nächste Aktion in der Plan-Phase und die Ausführung dieser in der Act-Phase.

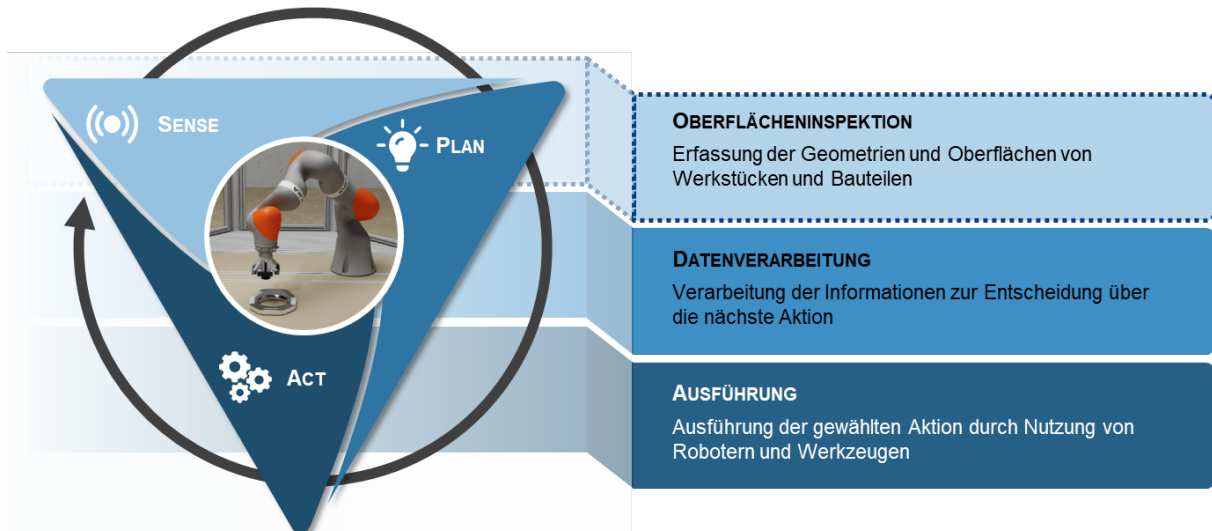


Abbildung 1: *Sense-Plan-Act-Paradigma am Beispiel der flexiblen Nachbearbeitung von Werkstücken oder Bauteilen*

Fokus dieses Beitrages soll die Auswahl und Diskussion geeigneter Inspektionsstrategien anhand zwei sehr unterschiedlicher Referenz-Use-Cases sein. Dies umfasst sowohl die Auswahl des Sensors als auch des entsprechenden Algorithmus für die Auswertung mittels analytischer oder Machine-Learning (ML)-basierter Ansätze. Dieser muss alle notwendigen Informationen bereitstellen, die für die Plan und Act-Phase notwendig sind. In **Abbildung 2** und **Tabelle 1** wird dabei deutlich, dass die jeweiligen Voraussetzungen und Anforderungen mitunter gegensätzlich sind, sodass sich die relevanten Kriterien zur Auswahl einer Inspektionsstrategie besonders anschaulich erklären lassen.

2 Referenz-Use-Cases

Der erste Referenz-Use-Case stammt aus dem Bereich der Nachbearbeitung von vakuumtechnischen Komponenten. Aufgrund dieses Anwendungsbereiches bestehen nicht nur hohe Anforderungen an die Präzision an sich, sondern auch an die Oberflächenqualität, insbesondere im Fall von Dichtflächen. Diese Dichtflächen weisen ein markantes Schleifriefenmuster auf, in welchem die Schleifriefen parallel zur Außenkontur und somit senkrecht zur potenziellen Leckagerichtung eingebracht werden. Jegliche Abweichungen von dieser Textur, insbesondere quer auf diesem Muster verlaufende Kratzer bedeuten eine potenzielle Leckage und sind somit unbedingt zu vermeiden [13]. Geprüft werden die Flächen aktuell rein manuell durch optische Begutachtung und eine entsprechende (ebenfalls manuell durchgeführte) Nachbearbeitung. Nach definierten Montageschritten sowie der finalen Endmontage erfolgen Leckagetests durch das Einbringen und Messen von Helium-Atomen. Gewünscht wird eine möglichst frühzeitige und automatisierte Detektion der Querkratzer. Der nachfolgende Schritt wäre daraufhin die Kombination dieser Inspektion mit einer entsprechend automatisierten Nachbearbeitung.



USE CASE 1	USE CASE 2
Feine Kratzer auf der Oberfläche	Gut sichtbare Vertiefungen und Erhebungen auf der Oberfläche
Präzises 3D-Modell vorhanden	Hohe Maßhaltigkeitstoleranzen (kein präzises Modell vorhanden)
Bearbeitung <ul style="list-style-type: none"> • Manuelle Nachbearbeitung durch Führung von Schleifpapier auf der Oberfläche • Geringer Materialabtrag (<1mm) • geringe Prozesskräfte 	Bearbeitung <ul style="list-style-type: none"> • Manuelle Nachbearbeitung durch Führung eines Winkelschleifers über die Oberfläche zur Erzeugung einer ebenen Oberfläche • Signifikanter Materialabtrag (>1mm) • Signifikante Prozesskräfte

Abbildung 2: Referenz Use Cases: Nachbearbeitung vakuumtechnischer Komponenten (links) und Nachbearbeitung von Schmiedeteilen (rechts)

Der zweite Referenz-Use-Case behandelt den Nachbearbeitungsprozess von Schmiedeteilen. Konkret geht es hier um die Nachbearbeitung von Schäkeln. Ein Schäkel ist ein U-förmiges Verbindungselement aus Metall, welches mittels eines Bolzens oder Schraubstiftes verschlossen wird und somit das Heben von Lasten mittels Seilen oder Ketten ermöglicht. Die betrachteten Schäkeln werden für den Schiffsbau eingesetzt und weisen Dimensionen bis zu mehreren Metern auf. Die Schäkeln werden einem Gesenkschmiedeprozess geformt. Dabei wird ein Werkstück unter hoher Temperatur in speziell geformten Matrizen (Gesenk) plastisch verformt [14]. Bei diesen Prozessen können zahlreiche Fehler auftreten, welche zu optischen Fehlern, vor allem aber auch zu einer Beeinträchtigung der Funktion durch Erzeugung von Kerbwirkung führen können.

Die Gestaltung des Gesenks, die Menge an Rohmaterial sowie die Temperatur beeinflussen den Materialfluss und können zu potenziell nicht ausgefüllten Bereichen und somit zu Löchern führen. Darüber hinaus können während des Abkühlungsprozesses Risse oder Oberflächenunregelmäßigkeiten durch eine unzureichende Reinigung der Gesenke entstehen [15]. Im Anschluss des Gesenkschmiedeprozesses werden die Enden des Schäkels stauchgeschmiedet und der Schäkel in seine U-Form gebogen. Die Toleranzen hinsichtlich der Maßhaltigkeit sind aufgrund dieser Prozesskette mit Schwankungen von bis zu +/- 5% vom Nennmaß als grob einzuordnen. Innerhalb dieser Grenzen werden die Bauteile mittels Winkelschleifer manuell nachbearbeitet, um eine ebene Oberfläche zu erzielen und somit Kerbwirkung zu vermeiden.

3 Stand der Technik

Zunächst erfolgt eine Definition des Fertigungsverfahrens Schleifens sowie des Begriffs der Oberflächenunvollkommenheiten. Im Anschluss werden unterschiedliche optische Sensortechnologien sowie relevante Verarbeitungsalgorithmen (analytische und ML-basierte) vorgestellt.

3.1 Industrielles Schleifen

Das Fertigungsverfahren Schleifen wird nach DIN 8589-0 als ein spanendes Fertigungsverfahren mit vielschneidigen Werkzeugen definiert, deren geometrisch unbestimmte Schneiden von einer Vielzahl gebundener Schleifkörper aus natürlichen oder synthetischen Schleifmitteln gebildet werden und mit hoher Geschwindigkeit den Werkstoff abtrennen. Die Normen DIN 8589-11 bis DIN 8589-13 befassen sich mit dem Schleifen mit rotierendem Werkzeug, Bandschleifen und Hubschleifen [16]. Für Use Case 1 ist dabei das Hubschleifen, für Use Case 2 das Schleifen mit rotierendem Werkzeug relevant.

3.2 Oberflächenunvollkommenheiten

In beiden Use Cases geht es um die Nachbearbeitung von sogenannten Oberflächenunvollkommenheiten (OU), welche in der DIN ISO 8785 als „Element oder Unregelmäßigkeit oder Gruppe von Elementen und Unregelmäßigkeiten der wirklichen Oberfläche, die unbeabsichtigt oder zufällig durch die Bearbeitung, Lagerung oder Funktion der Oberfläche entstanden sind“, definiert werden. Relevant ist dabei für die Betrachtung der Klasse der Kratzer, welche als „Vertiefung unregelmäßiger Form in nicht festgelegter Richtung“ definiert wird. Weitere Arten von Vertiefungen sind zum Beispiel Risse oder Poren. Des Weiteren werden nach außen gerichtete OU wie zum Beispiel Einschlüsse durch Fremdteilchen und Kombinationen nach innen und außen gerichteter OU wie Überlappungen durch Schmiede- oder Walzprozesse genannt [17].

3.3 Koordinatenmesstechnik

Je nach Anforderungen des Anwendungsfalles ist eine Detektion von OUs mit unterschiedlichen Messverfahren möglich. Innerhalb der Koordinatenmesstechnik wird in [18] zwischen taktilen und berührungslosen Messverfahren unterschieden. Taktile Sensoren, wie sie in Koordinatenmessmaschinen eingesetzt werden, weisen die höchste Genauigkeit im tausendstel Millimeterbereich auf, welche mit optischen 3D-Messsystemen nicht zu erreichen sind. Entscheidender Nachteil ist der hohe Zeitaufwand für die Erfassung von Geometrien, da stets nur punktuell gemessen wird und somit die Vermessung von hunderten von Punkten mehrere Stunden erfordert [19]. Gleiches gilt für die in [18] definierten lichtoptischen Sensoren, die jeweils Einzelpunkte mittels Triangulation, unterschiedliche Farben (chromatische Sensoren) oder Interferometrie Einzelpunkte vermessen. Im Fall der berührungslosen bildgebenden Sensoren lassen sich grundsätzlich 2D und 3D Messverfahren unterscheiden, deren Messbereich entsprechend eine Fläche oder ein Volumen umfasst. Aufgrund der höheren Effizienz der Erfassung von Bauteilen, werden für die weitere Analyse ausschließlich diese betrachtet, wobei vorausgesetzt wird, dass die Genauigkeit des Messverfahrens ausreichend hoch ist.

3.4 Bildgebende berührungslose Sensoren

Neben dem bildgebenden Sensor der Kamera besteht ein Visionsystem zudem aus einer Beleuchtungseinheit, einer Optik (einem Objektiv) sowie einer Bildverarbeitungseinheit [20]. Bildsensoren (CCD oder CMOS) wandeln das eingefallene Licht in elektrische Ladungen aufgrund des inneren Photoelektrischen Effekt und somit in entsprechende Spannungssignale um. Relevante

Parameter bei der Auswahl eines solchen Sensors sind Pixelanzahl und Pixelgröße [21]. Die Einstellung des Fokus am Objektiv legt die Ebene in z-Richtung fest, welche scharf abgebildet wird. Die Brennweite beeinflusst die Größe des Sichtfeld und, gemeinsam mit der Blendenöffnung, die Tiefenschärfe. Die Wahl der richtigen Beleuchtung ist für alle Vision-Anwendungen relevant und wird durch Lichtquelle, das Spektrum, die Form, die Position und die Strahlausrichtung bestimmt [22]. Die Verarbeitungselektronik verarbeitet die Spannungssignale mittels Analog-/Digitalwandlern und gibt diese über eine Kommunikationsschnittstelle in vorverarbeiteter Form weiter [21].

Zur Erfassung von Tiefeninformationen stehen unterschiedliche Technologien zur Verfügung. Dazu zählen das Laser-Triangulationsverfahren, das Stereo-Vision-Verfahren sowie das Time-of-Flight-Verfahren (siehe Abbildung 3). Beim Laser-Triangulationsverfahren wird ein Laserstrahl mittels einer Optik auf das Messobjekt gerichtet. Dieses Licht wird diffus reflektiert und wird dann von einer weiteren Optik auf einen Bildsensor (CCD) gerichtet. Auf Basis der Position der Abbildung auf dem Sensor und mit bekanntem Winkel zwischen Laserquelle und Sensor kann dann der Abstand eindeutig berechnet werden [23]. Passive Stereo-Vision basiert auf der Verwendung von zwei Bildsensoren mit einem definierten Abstand, welche auf Basis korrespondierender Punkte in beiden Abbildungen Tiefeninformationen ableiten. Korrespondierende Punkte werden dabei auf Basis von Pixelhelligkeiten oder Kanten gefunden, sodass nur schwach texturierte Oberflächen schwer bis nicht erfasst werden können. Im Unterschied zu diesem passiven Verfahren basiert Active Stereo Vision auf dem Prinzip der Projektion eines (Streifen-) Musters auf die Oberfläche des Objektes, sodass auf Basis der Verformung des Musters eine Tiefenberechnung ermöglicht wird. Dies kann entweder mit einem oder zwei Bildsensoren erfolgen [24]. Das Time-of-Flight-Verfahren basiert auf der Messung des verzögerten Echos einer reflektierten Lichtwelle. Die Lichtwelle wird entweder als rechteck- oder sinusförmigen Signales gesendet und die Phasenverschiebung des reflektierten Signales zur Bestimmung des Abstands genutzt [25]. Dieses Verfahren ist im Vergleich zu den anderen beiden Verfahren das mit der geringsten Genauigkeit. Alle drei Verfahren basieren auf dem Prinzip der diffusen Reflexion des Lichtes. Spiegelnde Oberfläche, welche nicht diffus reflektieren, sowie mattschwarze Oberfläche, welche nur schwach reflektieren, sind daher schwierig zu erfassen [26].




Abbildung 3: Bildgebende 3D-Messverfahren (v.l.n.r.: Lasertriangulation, Stereo-Vision, Time-of-Flight)

3.5 Verarbeitungsalgorithmen

Die Detektion der Oberflächenunvollkommenheiten auf den Werkstücken erfordert nach der Datenerfassung eine entsprechende Verarbeitung. Dabei ist es grundsätzlich möglich, analytische (deterministische) oder stochastische (ML-basierte) Algorithmen zu nutzen. Während analytische Algorithmen auf explizit definierten Regeln basieren, lernen ML-basierte Algorithmen implizit auftretende Muster in Datensätzen. Klare Vorteile analytischer Algorithmen sind Ihre Transparenz sowie ihre – im Vergleich zu komplexen ML-Modellen – hohe Recheneffizienz. Zudem werden keine Trainingsdaten benötigt. Auf der anderen Seite stoßen analytische Algorithmen an Grenzen, sobald eine hohe Variabilität im Prozess auftritt, da sie schlecht auf unbekannte Szenarien generalisieren. Um alle möglichen Szenarien abzubilden, müssten entsprechende Fallunterscheidungen und Regeln von Experten festgelegt werden, was je nach Anwendungsfall beliebig aufwändig und komplex werden kann.

Dies können sowohl wechselnde Umgebungsbedingungen (vor allem Beleuchtung), eine ungeordnete Bereitstellung von Werkstücken oder auch eine generell hohe Varianz innerhalb der Werkstücke sein. Hier liegt dann der Vorteil der ML-Algorithmen, welche diese Regeln implizit auf Basis von Daten erlernen und somit auch auf unbekannte Szenarien generalisieren können [27–30].

3.6 2D Verarbeitungsalgorithmen zur Defektklassifizierung

Konventionelle (analytische) Bildverarbeitung reicht bis in die 1960er Jahre zurück. Ein bekanntes Beispiel ist der Sobel-Operator zur Detektion von Intensitätsunterschieden zwischen Pixeln. Aufgrund dieser Eigenschaft wird er häufig für die Detektion von Kanten eingesetzt. Der Sobel-Operator differenziert das Bild in horizontaler und vertikaler Richtung, indem eine Filtermatrix (Kernel) durch Faltung (pixelweise Multiplikation) auf das Bild angewendet wird und somit die Gradienten in x- und y-Richtung berechnet werden. Größere Gradienten bedeuten dabei einen hohen Intensitätsunterschied. Es erfolgt die Festlegung von Schwellenwerten zur Bestimmung, ab welcher Gradientenstärke eine Kante vorliegt. Der Sobel-Operator weist eine hohe Anfälligkeit für Bildrauschen auf, die zu einer falsch positiven Kantendetektion führen. Dies behebt der Canny-Kantendetektor, indem er vor der Faltung eine Glättung des Bildes mit einem Gauß-Filter vornimmt [31, 32]. Darüber hinaus gibt es viele weitere Algorithmen ähnlicher Art, deren Applikation einen entsprechenden Fachexperten erfordert [27].

Die Basis-Architektur von ML-Algorithmen, welche zur Bildverarbeitung eingesetzt werden, sind in den meisten Fällen sogenannte Convolutional Neural Network (CNN)-Layers, welche ebenfalls eine Faltung zur Merkmalsextraktion vornehmen und anschließende Pooling-Layers zur Dimensionsreduktion und Aggregation von globalen Merkmalen. Die anschließende Bewertung dieser Merkmale erfolgt über Fully-Connected-Layers. Sowohl die Kernel als auch die Schwellenwerte, die in der klassischen Bildverarbeitung fest programmiert werden, werden hier durch Training auf gelabelten Bilddaten gelernt [27, 33].

Eines der bekannten Architekturen ist der YOLO-Algorithmus, welcher mittlerweile in der elften Version optimiert und zudem in unterschiedlichen Größen (von nano bis large) zur Verfügung steht [34]. Die Herausforderung der Aggregation einer ausreichend großen und repräsentativen Trainingsdatenmenge sowie der Aufwand des Labelings motivieren den Einsatz synthetischer Trainingsdaten [35, 36].

3.7 3D Verarbeitungsalgorithmen

Ein naheliegender Ansatz zur Detektion von Abweichungen einer gemessenen Punktwolke von einer Soll-Geometrie ist der Soll-Ist-Vergleich. Der Iterative Closest Point Algorithmus sorgt dabei für ein Alignment von Soll- und Ist-Modell, sodass Abweichungen deutlich werden [37]. Ist kein (ausreichend präzises) Soll-Modell vorhanden, so bieten sich unterschiedliche modellfreie Ansätze an. Diese basieren in der Regel auf der Analyse von Punktwolkendichten, von Oberflächennormalen und der Oberflächenkrümmung. In der Literatur finden sich dabei unterschiedliche Ansätze. So wurden in [38] Defekte auf einem Windturbinenblatt durch Abweichungen in den Oberflächennormalen detektiert. Die Oberfläche im Messbereich war dabei annähernd eben, sodass die reine Betrachtung dieses Parameters ausreichend war. Eine komplexere Analyse wurde in [39] durchgeführt, indem sie zusätzlich noch die Oberflächenkrümmung mit einbezogen, um Defekte auf Flugzeugbauteilen durchführten. Bei beiden Ansätzen ist das Tuning der entsprechenden Parameter und Schwellenwerte entscheidend für die erfolgreiche Detektion.

3D-Defekterkennung mittels maschinellen Lernens erfolgt entweder durch die Umwandlung von Punktwolken in 2D-Daten oder durch direkte Verarbeitung der Rohdaten [40].

Bei den projektionsbasierten Methoden werden 3D-Daten in verschiedene 2D-Repräsentationen z. B. mittels des Multi-View-Ansatzes [41], umgewandelt, die anschließend mit etablierten CNN-Layers analysiert werden. Direkt punktbasierte Ansätze verarbeiten die unstrukturierten Punktwolken direkt und nutzen dabei unterschiedliche Ansätze. PointNet z.B. verarbeitet jede Punktkoordinate einzeln durch Fully Connected Layers und aggregiert globale Merkmale durch Pooling-Funktionen [42]. Ein hybrider Ansatz kombiniert beide Verfahren, indem zunächst Defekte in 2D erkannt und anschließend präzise in den 3D-Daten lokalisiert werden [40].

4 Lösungskonzept

Trotz der Unterschiede der beiden Use-Cases sind die Abläufe der adaptiven Bearbeitung ähnlich (siehe Abbildung 4). Zunächst gilt es, das Bauteil zu lokalisieren und, da häufig die Inspektion aus einer Perspektive nicht ausreichend ist, die Berechnung einer Inspektionstrajektorie, die der Roboter, an dessen Endeffektor eine entsprechende Kamera befestigt ist, durchführt. Dies kann entweder durch festgelegte Inspektionsposen oder über einen flexiblen Ansatz über Next-Best-View-Algorithmen, welche iterativ die nächste beste Sensorausrichtung berechnen, erfolgen [43, 44]. Nach der so durchgeführten Datenaufnahme erfolgt dann die Verarbeitung der Informationen und basierend darauf die eigentliche Bearbeitung. Im Anschluss kann erneut geprüft werden. Dies kann iterativ wiederholt werden, bis das gewünschte Ergebnis erreicht wurde. Anzustreben ist eine möglichst geringe Anzahl an Iterationsschleifen.

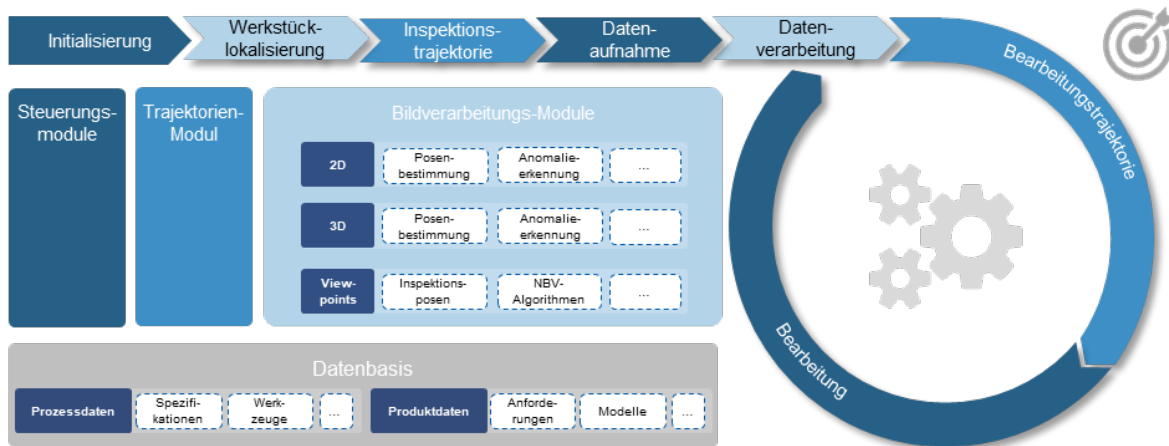


Abbildung 4: Ablauf von roboterbasierten Schleifprozessen und Modularchitektur

Aufgrund der unterschiedlichen Anforderungen von Use-Cases, ist es sinnvoll, die Funktionalitäten in Form von Modulen zu kapseln. Die Art der Module lassen sich in Steuerungs-Module zur Ansteuerung von Geräten wie dem Roboter, dem Vision-System oder auch Bearbeitungswerkzeugen, Trajektorienmodule zur modell- oder messungsbasierten Berechnung von Trajektorien und den Bildverarbeitungs-Modulen zur Auswertung der erfassten Daten unterteilen.

4.1 Auswahl der Sensortechnologien

Im Folgenden wird die Auswahl der Sensortechnologien für die jeweiligen Sensortechnologien diskutiert, wobei die Kriterien Tabelle 1 zu entnehmen sind. Im Fall der vakuumtechnischen Komponenten handelt es sich um Kratzer mit einer Breite und Tiefe im Submillimeterbereich. Aufgrund der geringen Dimension sowie der Herausforderung, diese Tiefe mit bildgebender 3D-Sensorik zu erfassen, bietet sich hier eher ein 2D-Ansatz an. Da die Erkennung mit bloßem Auge unter der richtigen Beleuchtung möglich ist, wird eine Industriekamera mit entsprechender Genauigkeit als geeignet eingestuft. Die 3D-Modelle, die von den Komponenten vorhanden sind, sind für eine Bearbeitung ausreichend präzise, sodass keine 3D-Geometrieerfassung notwendig ist. Die Tiefenbestimmung der jeweiligen Kratzer als Voraussetzung für die Ableitung einer Bearbeitungsstrategie, sprich die Trajektorie (insbesondere die Häufigkeit, in der mit dem Schleifpapier über den Kratzer gefahren werden muss) oder auch der Anpressdruck, ist somit nicht möglich. Potenziell bedeutet dies ein häufigeres Durchlaufen des skizzierten Zyklus in Abbildung 4. Durch den geringen Materialabtrag sowie die trockene Bearbeitung wird die Sicht jedoch weitestgehend nicht beeinträchtigt, sodass dies als unkritisch eingestuft wird. Aufgrund des geringen Materialabtrags und der geringen Prozesskräfte lässt sich das automatisierte Szenario mittels eines kollaborativen Roboters umsetzen, welcher in die werkstatorientierte Fertigung des Unternehmens integriert wird. Dieses Szenario hat vor allem für KMU eine hohe Relevanz und ermöglicht die einfache Integration von flexiblen Automatisierungslösungen.

Tabelle 1: Kriterien zur Auswahl der Sensortechnologie

Messverfahren	2D		3D	
	Geringe Tiefenausprägung (< 1mm)		Signifikante Tiefenausprägung (>1mm)	
	Präzises 3D-Modell vorhanden		Geometrieerfassung notwendig	
	Iterative Bearbeitungsstrategie		Sequenzielle Bearbeitungsstrategie	
	<ul style="list-style-type: none"> Geringe Bearbeitungszeiten (mehrere Iterationsschleifen möglich) geringer Materialabtrag (geringe Spanbildung) trockene Bearbeitung (keine Sichtbeeinträchtigung durch Kühlschmierstoffe) 		<ul style="list-style-type: none"> Höhere Bearbeitungszeiten (wenige Iterationsschleifen vorteilhaft) Signifikanter Materialabtrag (Sichtbeeinträchtigung durch Spanbildung) Sichtbeeinträchtigung durch Kühlschmierstoffe 	
Algorithmus	analytisch	ML-basiert	analytisch	ML-basiert
	Konstante Lichtverhältnisse	Wechselnde Lichtverhältnisse	Präzises 3D-Modell vorhanden	Kein präzises 3D-Modell vorhabenden
	Konstante Kameraperspektive	Wechselnde Kameraperspektive	Einfache Bauteilgeometrien	Komplexe Bauteilgeometrien
	Geringe Variation der Anomalien	Hohe Variationen der Anomalien	Eindeutige Anomaliecharakteristik	Variierende Anomaliecharakteristik
	Konstante Oberflächenbeschaffenheit	Variierende Oberflächenbeschaffenheit	Geringe Variation der Messfehler	Hohe Variation von Messfehlern

Im Fall des zweiten Use-Cases sprechen Bauteilgröße, Prozesskräfte und auch Materialabtrag hingegen klar für eine klassische Industrieroboterlösung in einer abgeschlossenen Zelle. Aufgrund der Schwankungen der Geometrien der Schäkel um mehrere Zentimeter ist davon auszugehen, dass vor Erstellung eines Bearbeitungsprogrammes eine Vermessung in 3D erforderlich sein wird. Die Defekte, welche nachbearbeitet werden müssen, sind in ihrer Tiefenausprägung größer als 1 mm, flachere Defekte müssen nicht nachbearbeitet und somit auch nicht detektiert werden. Lasertriangulations- und Stereo-Vision-Verfahren verfügen jedoch laut [26, 45] über die notwendige Präzision zur Vermessung im Submillimeter-Bereich. Aufgrund der erforderlichen 3D Vermessung soll zunächst dieser Ansatz evaluiert werden. Durch eine zusätzliche Tiefenbestimmung und eine Kenntnis der Prozessparameter (Zusammenhang des Anpressdruckes und der Trajektorie mit dem Spanvolumen), lässt sich die Anzahl der in Abbildung 4 skizzierten Iterationen potenziell verringern.

4.2 Auswahl der Verarbeitungsalgorithmen

Nach der Auswahl der Sensortechnologien folgt nun die Auswahl der Verarbeitungsalgorithmen. Zum Zeitpunkt der Veröffentlichung liegt eine erste Vorstudie vor, die aber noch weiterer Evaluation bedürfen.



Abbildung 2: Bildverarbeitung mittels Canny-Algorithmus

Im Fall der vakuumtechnischen Komponenten wird ein Referenzbauteil, ein Zwischenflansch, gewählt und hinsichtlich der Möglichkeit, Kratzer auf der Oberfläche mittels des Canny-Algorithmus zu detektieren. Die Ergebnisse sind in Abbildung 5 zu erkennen. Zwar werden Kanten und der eine Kratzer herausgefiltert, jedoch stechen auch die durch die Lichtreflexion die (gewollten) Schleifriefen in ähnlicher Deutlichkeit wie der schmalere Kratzer rechts im Bild hervor. Die Unterscheidung von Kratzern und Schleifriefen durch entsprechendes Parametertuning ist somit als schwierig anzusehen. Zudem werden die gefundenen Parameter sehr sensibel auf Veränderungen der Beleuchtung reagieren. Im Hinblick auf ein Setting, bei dem der kollaborative Roboter in die werkstattorientierte Fertigung des Unternehmens integriert wird, ist die Sicherstellung konstanter Beleuchtung und Umgebungsbedingungen herausfordernd.

Aufgrund der höheren Robustheit gegenüber wechselnden Umgebungsbedingungen soll hier ein Machine-Learning-Model genutzt werden. Aufgrund der vielversprechenden Ergebnisse hinsichtlich der Nutzung synthetischer Daten für die Kratzerdetektion auf metallischen Oberflächen [35], wird dieser Ansatz hier weiterverfolgt. Im Vergleich zu dieser Arbeit, in welcher ein einfaches Aluminiumblech verwendet wurde, ist das hier genutzte Bauteil von seiner Geometrie und der Schleifgeometrie her komplexer und erfordert daher zusätzliche Schritte der Meshbearbeitung, dem sogenannten UV-Unwrapping.

Dies kann beispielsweise mittels des Programmes Blender realisiert werden. Über die Nutzung der Python API ist dabei sowohl eine Automatisierung dieses Schrittes sowie die Integration in eine geschlossene Datenerzeugungs- und Trainingspipeline möglich. Nach dem Schritt des UV-Unwrapping kann dann das Bauteil in der Umgebung inklusive Roboter und Zelle simuliert werden (siehe Abbildung 6). Nach Übertragung der relevanten Kamera- und Objektivparameter (Brennweite, Fokus, Blendenöffnung etc.) können fotorealistische Bilder erzeugt werden. Ein Machine-Learning Modell kann nach dem Training auf synthetischen Daten dann auch Kratzer auf realen Bauteilen erkennen. Erste Ergebnisse mit dem YOLO v11 nano Modell validieren bereits einen ersten Proof-of-Concept, jedoch besteht ein weiterer Evaluationsbedarf hinsichtlich des Einflusses von Beleuchtung, Randomisierungsparametern und anderer ML-Architekturen.




Abbildung 6: Automatisierte Pipeline zum Training eines Machine-Learning-Modells mit synthetischen Bilddaten

Auch für den zweiten Anwendungsfall soll zunächst ein analytischer Ansatz entwickelt und evaluiert werden. Dazu wird ein modellfreier Algorithmus entwickelt, welcher basierend auf der Analyse von Normalen und der Krümmung Anomalien detektiert. Auf Basis der Vorarbeiten von [38, 39] gilt es dabei, diese auf den konkreten Use-Case der Schäkelgeometrie anzupassen und in diesem Zuge zu untersuchen, inwieweit dies auch auf andere Geometrien angewendet werden kann. Die verschiedenen Schritte sind in Abbildung 7 zu erkennen. Zu erwarten ist eine hohe Abhängigkeit der Ergebnisse von Parametern wie der Anzahl an Nachbarpunkten für die Bestimmung von Normalen sowie Grenzwerten von Abweichungen der Normalen und Krümmungen. So stellt beispielsweise die Unterscheidung von einer Kante und einer lokalen Erhebung/Vertiefung eine Herausforderung dar.

Ergebnis der Analyse sollen nicht nur die lokalisierten Defekte, sondern auch die Bestimmung der Tiefe sein, um, basierend auf diesen Informationen, eine Bearbeitungsstrategie zu bestimmen. Erste Ergebnisse auf rein simulierten Ergebnissen sind vielversprechend, jedoch ist die Evaluation der Performanz auf Realdaten entscheidend. So könnte Messrauschen auftreten oder durch die Reflektionen auf dem metallischen Bauteil Löcher in der Punktwolke entstehen, die robuste Erkennung von OU erschweren. Sowohl die Robustheit als auch die Recheneffizienz könnte durch die Integration von Modellwissen gesteigert werden. Dies könnte ebenfalls die genaue Bestimmung der Tiefe eines Defektes unterstützen, welche für die nachgelagerte Bestimmung einer Bearbeitungsstrategie entscheidend ist.

Darüber hinaus wäre hier auch ein ML-basierter Ansatz denkbar, um auch auf unbekanntem Geometrien Defekte durch Generalisierung zu erkennen.




Abbildung 7: Detektion von Vertiefungen und Erhebungen mittels eines analytischen, modellfreien Algorithmus

4.3 Zusammenfassung und Ausblick

In diesem Beitrag wurde die Eignung unterschiedlicher Inspektionsstrategien im Kontext der roboterbasierten Automatisierung von Schleifprozessen anhand von zwei Referenz-Use-Cases diskutiert. Da bereits ein breites Spektrum an weit entwickelten und präzisen Sensortechnologien und Verarbeitungsalgorithmen existiert, ist es entscheidend, die für den Anwendungsfall am besten geeigneten zu wählen. Die Frage, ob ein 2D- oder ein 3D-Ansatz (oder sogar eine Kombination beider) geeignet ist, hängt maßgeblich von den Dimensionen von Bauteil/ Werkstück und denen der Oberflächenunvollkommenheiten ab. Darüber hinaus beeinflusst diese Entscheidung, ob der Bearbeitungsprozess eher iterativ in mehreren Zyklen oder sequenziell ablaufen kann. Bei der Wahl der Algorithmen ist es häufig ratsam, zunächst einen analytischen Ansatz heranzuziehen, da analytische Modelle transparent und häufig weniger rechenintensiv sind. Sollte sich der analytische Ansatz aufgrund der Komplexität des Anwendungsfalls (beispielsweise durch Reflexionen oder durch die Geometrie des Bauteils) als zu hoch erweisen, bieten Machine Learning Algorithmen eine gute Alternative, deren großer Nachteil des hohen Bedarfs an gelabelten Trainingsdaten durch synthetische Datenerzeugung egalisiert werden kann.

4.4 Danksagung

Die hier dargestellten Erkenntnisse wurden im Rahmen der beiden BMBF-geförderten Projekt „Demonstrations- und Transfernetzwerk KI in der Produktion (ProKI-Netz)“ sowie dem Verbundprojekt „Arbeitswissenschaftliches Kompetenzzentrum für Erwerbsarbeit in der Industrie 4.0 - AKzentE4.0“ erworben.

5 References

- [1] Hoffmann Group, Optimale Ergebnisse: Schweißen gut vor- und nachbereiten. [Online]. Available: <https://www.hoffmann-group.com/DE/de/hom/wissen/online-ratgeber/ratgeber-schleif-und-trenntechnik/schweissnahtbearbeitung/e/500845/> (accessed: Jul. 12 2024).
- [2] Gustav Buchholz GmbH & Co. KG, Nachbearbeitung von Gussteilen. [Online]. Available: <https://www.giesserei-buchholz.com/giesserei/nachbearbeitung-gussteile/>
- [3] 3M, Automatisierung von Schleifprozessen. [Online]. Available: https://www.3mdeutschland.de/3M/de_DE/metallverarbeitung-de/anwendungen/roboter-schleifen/ (accessed: Jul. 12 2024).
- [4] Ferrobotics, Schleifen, Polieren, Entgraten: DIE PERFEKTE OBERFLÄCHE IN JEDEM UMFELD. [Online]. Available: <https://www.ferrobotics.com/know-how/branchen-anwendungen/schleifen-polieren-entgraten/>
- [5] Arcos, CASE STUDIES FOR AUTOMOTIVE SECTOR. [Online]. Available: <https://www.arcossrl.com/en/automotive/> (accessed: Jul. 12 2024).
- [6] Acme, Automotive Robotic Metal Finishing. [Online]. Available: <https://acmemfg.com/automotive-metal-finishing/> (accessed: Jul. 12 2024).
- [7] BGHM Berufsgenossenschaft Holz und Metall, "Scheifen," [Online]. Available: <https://www.bghm.de/arbeitschuetzer/fach-themen/oberflaechenbehandlung/schleifen/>
- [8] KfW, "Wettbewerbsdruck auf Mittelständische Unternehmen in Deutschland wächst seit Jahren," 2013. [Online]. Available: https://www.kfw.de/%C3%9Cber-die-KfW/Newsroom/Aktuelles/News-Details_155008.html

- [9] Bundesministerium für Arbeit und Soziales, Fachkräftemonitoring für das BMAS – Mittelfristprognose bis 2027. [Online]. Available: https://www.bmas.de/SharedDocs/Downloads/DE/Publikationen/Forschungsberichte/fb-625-fachkraefte-monitoring-bmas-mittelfristprognose-2027.pdf?__blob=publicationFile&v=3 (accessed: 13.09,2024).
- [10] P. Kahhal, Y.-K. Jo, and S.-H. Park, "Recent Progress in Remanufacturing Technologies using Metal Additive Manufacturing Processes and Surface Treatment," *Int. J. of Precis. Eng. and Manuf.-Green Tech.*, 2023, doi: 10.1007/s40684-023-00551-2.
- [11] D. Poll, "Robotik: Automatisiert Entgraten, Schleifen und Polieren," *Produktion - Technik und Wirtschaft für die deutsche Industrie*. <https://www.produktion.de/technik/robotik-automatisiert-entgraten-schleifen-und-polieren-116.html>
- [12] S. J. Russell and P. Norvig, *Artificial intelligence: A modern approach*. Boston: Pearson, 2022. [Online]. Available: <https://elibrary.pearson.de/book/99.150005/9781292401171>
- [13] M. Wutz, H. Adam, W. Walcher, and K. Jousten, "Lecksuchtechnik," in *Springer eBook Collection Life Science and Basic Disciplines, Handbuch Vakuumtechnik*, M. Wutz, H. Adam, W. Walcher, and K. Jousten, Eds., 7th ed., Wiesbaden, s.l.: Vieweg+Teubner Verlag, 2000, pp. 468–494.
- [14] E. Doege and B.-A. Behrens, *Handbuch Umformtechnik: Grundlagen, Technologien, Maschinen*, 3rd ed. Berlin, Heidelberg: Springer Berlin Heidelberg, 2018. [Online]. Available: <http://nbn-resolving.org/urn:nbn:de:bsz:31-epflicht-1502756>
- [15] *An Overview of Forging Process and Defects in Hot and Cold Forging*, 2022.
- [16] *Fertigungsverfahren Spanen, Schleifen mit rotierendem Werkzeug, Bandschleifen, Hubschleifen, DIN 8589-11-13*.
- [17] *Geometrische Produktspezifikation (GPS) Oberflächenunvollkommenheiten Begriffe, Definitionen und Kenngrößen, ISO 8785 : 1998*.
- [18] E. Hering, "Sensoren," in *Elektronik für Ingenieure und Naturwissenschaftler*, E. Hering, J. Endres, and J. Gutekunst, Eds., 8th ed., Berlin, Heidelberg: Springer Vieweg, 2021, pp. 389–412.
- [19] Carl Zeiss AG, *Taktile und optische Messtechnik: Vorteile, Unterschiede und Anwendungsbereiche*. [Online]. Available: <https://www.zeiss.de/messtechnik/entdecken/themen/taktile-und-optische-messtechnik.html> (accessed: Feb. 27 2025).
- [20] C. Demant, B. Streicher-Abel, and A. Springhoff, *Industrielle Bildverarbeitung: Wie optische Qualitätskontrolle wirklich funktioniert*, 3rd ed. Berlin, Heidelberg: Springer-Verlag Berlin Heidelberg, 2011. [Online]. Available: <http://site.ebrary.com/lib/alltitles/docDetail.action?docID=10439943>
- [21] A. El Gamal and H. Eltoukhy, "CMOS image sensors," *IEEE Circuits Devices Mag.*, vol. 21, no. 3, pp. 6–20, 2005, doi: 10.1109/MCD.2005.1438751.
- [22] *Technische Bildverarbeitung - maschinelles Sehen*. Berlin, Heidelberg: Springer, 1996.
- [23] J. Beyerer, F. Puente León, C. Frese, and J. Meyer, *Automatische Sichtprüfung: Grundlagen, Methoden und Praxis der Bildgewinnung und Bildauswertung*, 3rd ed. Berlin, Heidelberg: Springer Vieweg, 2024.
- [24] Y.-J. Zhang, *Handbook of Image Engineering*, 1st ed. Singapore: Springer Singapore; Imprint Springer, 2021.

- [25] M. Hansard, *Time-Of-Flight Cameras: Principles, Methods and Applications*, 1st ed. London: Springer London Limited, 2013.
- [26] M. Marxer, C. Bach, and C. P. Keferstein, *Fertigungsmesstechnik: Alles zu Messunsicherheit, konventioneller Messtechnik und Multisensorik*, 10th ed. Wiesbaden: Springer Vieweg, 2021.
- [27] N. O'Mahony(&) et al., "Deep Learning vs. Traditional Computer Vision," pp. 128–144, 2020.
- [28] R. Ameri, C.-C. Hsu, and S. S. Band, "A systematic review of deep learning approaches for surface defect detection in industrial applications," *Engineering Applications of Artificial Intelligence*, vol. 130, p. 107717, 2024, doi: 10.1016/j.engappai.2023.107717.
- [29] I. H. Witten, *Data mining: Practical machine learning tools and techniques*, 3rd ed. Burlington, MA: Morgan Kaufmann Publishers, 2011. [Online]. Available: <https://learning.oreilly.com/library/view/-/9780123748560/?ar>
- [30] C. M. Bishop, *Pattern Recognition and Machine Learning*, 1st ed. New York, NY: Springer New York, 2016. [Online]. Available: <http://www.springer.com/>
- [31] R. C. Gonzalez and R. E. Woods, *Digital image processing*. New York, New York: Pearson Education, 2018. [Online]. Available: <https://ebookcentral.proquest.com/lib/kxp/detail.action?docID=5573669>
- [32] R. Szeliski, *Computer vision: Algorithms and applications*. London: Springer, 2011. [Online]. Available: <https://ebookcentral.proquest.com/lib/kxp/detail.action?docID=6314456>
- [33] I. Goodfellow, A. Courville, and Y. Bengio, *Deep learning*. Cambridge, Massachusetts: The MIT Press, 2016. [Online]. Available: <https://search.ebscohost.com/login.aspx?direct=true&scope=site&db=nlebk&db=nlabk&AN=2565107>
- [34] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," Jun. 2015. [Online]. Available: <http://arxiv.org/pdf/1506.02640>
- [35] J. Monnet, O. Petrovic, and W. Herfs, "Investigating the generation of synthetic data for surface defect detection: A comparative analysis," *57th CIRP Conference on Manufacturing Systems 2024 (CMS 2024)*, (accepted, not yet published), 2024.
- [36] S. I. Nikolenko, "Synthetic Data for Deep Learning," Springer International Publishing, 2021.
- [37] P. J. Besl and N. D. McKay, "A method for registration of 3-D shapes," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 14, no. 2, pp. 239–256, 1992, doi: 10.1109/34.121791.
- [38] B. Alt et al., "RoboGrind: Intuitive and Interactive Surface Treatment with Industrial Robots," Feb. 2024. [Online]. Available: <http://arxiv.org/pdf/2402.16542>
- [39] I. Jovančević et al., "3D Point Cloud Analysis for Detection and Characterization of Defects on Airplane Exterior Surface," *J Nondestruct Eval*, vol. 36, no. 4, 2017, doi: 10.1007/s10921-017-0453-1.
- [40] A. Rani, D. Ortiz-Arroyo, and P. Durdevic, "Advancements in point cloud-based 3D defect classification and segmentation for industrial systems: A comprehensive survey," *Information Fusion*, vol. 112, p. 102575, 2024, doi: 10.1016/j.inffus.2024.102575.

- [41] M. Alzahrani, M. Usman, S. K. Jarraya, S. Anwar, and T. Helmy, "Deep models for multi-view 3D object recognition: a review," 12, 2024. [Online]. Available: <http://arxiv.org/pdf/2404.15224>
- [42] C. R. Qi, H. Su, K. Mo, and L. J. Guibas, "PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation," Dec. 2016. [Online]. Available: <http://arxiv.org/pdf/1612.00593>
- [43] C. Connolly, "The determination of next best views," in Proceedings. 1985 IEEE International Conference on Robotics and Automation, St. Louis, MO, USA, Mar. 1985, pp. 432–435.
- [44] C. M. de Melo, A. Torralba, L. Guibas, J. DiCarlo, and R. Chellappa, "Next-generation deep learning based on simulators and synthetic data," Trends in cognitive sciences, 26. Jg, no. 2, S. 174-187, 2022.
- [45] M. Sackewitz, Ed., Leitfaden zur optischen 3D-Messtechnik. Stuttgart: Fraunhofer-Verl., 2014.