

doi.org/10.37544/1436-4980-2026-06-58

Datum der Einreichung: 01.04.2026

Datum der Annahme: 20.04.2026

Datum der Veröffentlichung: 27.07.2026

Technische Zeichnungen mit lokalen KI-Modellen auswerten für die Herstellkostenkalkulation

KI-basierte Zeichnungsanalyse zur Kostenkalkulation

B. Denkena, K. M. Heide, M. Nein

ZUSAMMENFASSUNG Für zerspanende Lohnfertiger steigt der Druck, Herstellkosten in der Angebotsphase schnell und belastbar zu prognostizieren. Der Beitrag zeigt, wie technische Anforderungen aus „STEP“-Daten und technischen Zeichnungen maschinenlesbar erfasst werden können und wie sich die Symbolerkennung in Zeichnungen mit lokalen KI-Modellen verbessern lässt. Damit wird eine Grundlage für die automatisierte Arbeitsplanung und transparentere Kostenprognosen geschaffen.

AI-based drawing analysis for manufacturing cost estimation

ABSTRACT Contract machining companies are facing increasing pressure to quickly and reliably estimate production costs during the quotation phase. This article demonstrates how technical requirements can be captured in a machine-readable format from „STEP“ data and technical drawings, and how symbol recognition in drawings can be improved using local AI models. This lays the groundwork for automated work planning and more transparent cost estimates.

STICHWÖRTER

Kostenrechnung, Digitalisierung, Künstliche Intelligenz (KI)




Bild 1 Angebotspreise unterschiedlicher Anbieter nach Losgröße. Grafik: IFW

1 Einführung

Die Angebotsphase in der zerspanenden Lohnfertigung ist durch einen hohen Zeit- und Wettbewerbsdruck geprägt. Vor allem digitale Fertigungsplattformen ermöglichen es Kunden, CAD-Modelle und technische Zeichnungen innerhalb weniger Minuten bei mehreren Anbietern anzufragen und direkt einen Angebotspreis mit Liefertermin zu erhalten. In der Praxis zeigt sich bei einem Analogiebauteil, welches einem realen Struktur-

bauteil aus der Luftfahrt nachempfunden ist, dass die Angebotspreise der Anbieter teils stark voneinander abweichen (**Bild 1**).

Grundlage von Bild 1 ist eine Angebotsanfrage, bei der dieselbe „STEP“-Datei mit identischen Qualitätsanforderungen bei allen Plattformen hochgeladen und jeweils die längste Lieferzeit ausgewählt wurde. Die Auswertung zeigt, dass der Preisunterschied zwischen dem günstigsten und dem höchstpreisigen Angebot bereits bei Losgröße 1 bei einem Faktor von 2 liegt. Mit steigender Losgröße nehmen die Unterschiede weiter zu, sodass sich die Stückkosten bei einer Losgröße von 100 zwischen dem günstigsten




Bild 2 Schematischer Ablauf zur Erstellung von Kostenmodellen in der Angebotsphase. Grafik: IFW

tem und dem preislich höchsten Angebot um den Faktor 7 unterscheiden. Diese Preisstreuung kann unter anderem damit erklärt werden, dass die Plattformen häufig nicht selbst fertigen, sondern Aufträge an Netzwerke aus Lohnfertigern vermitteln und die Angebotsfindung über algorithmisch unterstützte Bewertungsverfahren erfolgt. Da sich diese Netzwerke teilweise über die ganze Welt erstrecken, kann unter Inkaufnahme längerer Lieferzeiten auch in Niedriglohnländern und anderen Währungsregionen produziert werden.

Weitere Unterschiede zwischen den Plattformen, die Einfluss auf die Preisbildung haben können, sind nicht Gegenstand der vorliegenden Betrachtung. Vergeben werden die Aufträge im Netzwerk häufig durch Zielpreise oder Bieterverfahren. Für die Lohnfertiger steigt so der Druck, die Herstellkosten der Bauteile in der eigenen Fertigungsumgebung belastbar in der Angebotsphase zu prognostizieren, ohne dafür einen unverhältnismäßig hohen manuellen Aufwand in der Arbeitsplanung zu verursachen. Erst auf dieser Basis lassen sich unter Berücksichtigung der künftigen Auslastung und strategischer Zielsetzungen fundierte Entscheidungen über Angebotspreise sowie über die Annahme oder Ablehnung von Fertigungsaufträgen mit vorgegebenem Fixpreis treffen.

Für die automatisierte Auswertung von 3D-Bauteilen und technischen Zeichnungen stehen verschiedene proprietäre Lösungen am Markt zur Verfügung. Deren Einsatz setzt aber oft voraus, dass die zugrunde liegenden Produktdaten zur Verarbeitung auf externe Cloud-Infrastrukturen übertragen werden. Dies steht in der industriellen Praxis nicht selten im Widerspruch zu vertraglichen Geheimhaltungsvereinbarungen und Anforderungen an den Schutz sensibler Kundendaten. Vor diesem Hintergrund gewinnen

lokal betreibbare Ansätze zur automatisierten Informationsauswertung zunehmend an Bedeutung.

Der vorliegende Beitrag untersucht, wie technische Zeichnungen als weiterhin zentrale Informationsquelle in der Angebotsphase automatisiert auf lokalen Rechnern ausgewertet werden können und wie dies die KI-gestützte Herstellkostenkalkulation in der Zerspanung unterstützt. Zunächst werden die Kostenkalkulation in der Angebotsphase, bestehende Kalkulationsmethoden sowie die Rolle der Arbeitsplanung eingeordnet. Darauf aufbauend werden die Herausforderungen beim Auslesen technischer Anforderungen und deren Überführung in Fertigungsabläufe dargestellt. Anschließend wird eine Methode zum automatisierten Auslesen technischer Zeichnungen vorgestellt und durch eine Evaluierung bewertet. Den Abschluss bilden eine Zusammenfassung der Ergebnisse und ein Ausblick auf weitere Forschungs- und Entwicklungsschritte.

2 Kostenkalkulation in der Angebotsphase

2.1 Kostenkalkulationsmethoden

In der Angebotsphase der zerspanenden Lohnfertigung besteht die Herausforderung darin, aus meist unvollständigen Produkt- und Prozessinformationen in kurzer Zeit einen belastbaren Angebotspreis abzuleiten [1, 2]. **Bild 2** zeigt den grundsätzlichen Ablauf bei der Erstellung eines Kostenmodells für die Angebotsphase auf.

Ausgangspunkt sind die zum Planungszeitpunkt verfügbaren Informationen, zu denen vor allem 2D- und 3D-Bauteilinformationen, bestehende Arbeitspläne, Betriebs- und Rückmeldedaten sowie Materialkosten, Kostensätze und historische Herstellkosten




Bild 3 Einordnung von Kostenkalkulationsverfahren in der Angebotsphase. Grafik: IFW

zählen [3]. Diese Informationen müssen zunächst in kostenrelevante Merkmale überführt werden. Hierzu werden geometrische, technologische und organisatorische Eigenschaften extrahiert und so aufbereitet, dass sie als numerische Eingangsgrößen, Entscheidungsregeln oder logische Beziehungen in einem Kalkulationsmodell genutzt werden können [4]. Aufbauend darauf kommen unterschiedliche Modellierungsansätze zum Einsatz, etwa Korrelationsanalysen, Entscheidungstabellen oder logikbasierte Verknüpfungen [1, 2]. Die eigentliche Schätzlogik kann regelbasiert, KI-basiert oder als Mischung beider Entscheidungsregeln ausgeprägt sein und führt je nach Zielsetzung zu Ähnlichkeitsanalysen, Kostenprognosen oder zur Synthese eines vorläufigen Arbeitsplans [1, 4].

Die Arbeitsplansynthese liefert vor allem bei neuen Bauteilen mit geringer Ähnlichkeit zu bereits gefertigten Referenzbauteilen den detailliertesten Aufschluss über die zu erwartenden Fertigungsaufwände und somit über die verursachten Herstellkosten, da sie die technischen Anforderungen schrittweise in konkrete Fertigungsabläufe, Ressourcenbedarfe und Zeitansätze überführt [3]. Die hierfür erforderlichen Teilentscheidungen können je nach Planungsschritt auf formelbasierten, algorithmischen oder erfahrungsbasierten Entscheidungslogiken beruhen [5]. Zur computergestützten Automatisierung erfahrungsbasierter Entscheidungen kommen vermehrt Methoden mit Nutzung von KI-Algorithmen zum Einsatz, die historische Bauteildaten mit historischen Produktionsdaten verknüpfen und auf neuen Bauteilen anwenden können. Beispielsweise hat *Hussong et al.* eine Methode zur KI-gestützten Auswahl von Fertigungsprozessen entwickelt [6]. Damit wird deutlich, dass die Herstellkostenkalkulation nicht allein aus einer mathematischen Kostenfunktion besteht, sondern aus einer mehrstufigen Informationsverarbeitung, in der Produktdaten, Erfahrungswissen und betriebliche Rückmeldungen zusammengeführt werden [1–3].

Die in **Bild 3** dargestellte Einordnung folgt der in der Literatur beschriebenen Unterscheidung in qualitative und quantitative Kostenschätzungsmethoden [2].

Qualitative Verfahren umfassen insbesondere Intuition oder Expertenurteil sowie den Ähnlichkeitsvergleich mit bereits kalku-

lierten oder gefertigten Referenzbauteilen. Sie sind vor allem dann zweckmäßig, wenn nur wenige Eingangsinformationen vorliegen und kurzfristig eine erste Preisindikation benötigt wird. Ihr Vorteil liegt im geringen Aufwand und in der hohen praktischen Verfügbarkeit. Nachteilig sind die begrenzte Nachvollziehbarkeit sowie die starke Abhängigkeit von Erfahrungswissen, geeigneten Vergleichsfällen und betriebspezifischen Randbedingungen [1, 2]. Der Ähnlichkeitsvergleich stellt eine formalisiertere Ausprägung qualitativer Verfahren dar, da Kosten aus vergleichbaren historischen Fällen unter Berücksichtigung geometrischer, technologischer oder organisatorischer Ähnlichkeiten abgeleitet werden. Solche referenzbasierten Ansätze sind vor allem bei Teilfamilien mit wiederkehrenden Merkmalen attraktiv, verlieren jedoch an Aussagekraft, wenn neuartige Bauteile, geänderte Fertigungsrandbedingungen oder stark abweichende Qualitätsanforderungen vorliegen [7, 8].

Quantitative Verfahren setzen dagegen eine stärkere Formalisierung der Kostenursachen voraus. Einen Übergang zwischen grober Schätzung und detaillierter Prozessabbildung bilden parametrische Kalkulationsmethoden, bei denen die Herstellkosten über ausgewählte Kostentreiber, wie Werkstoff, Abmessungen, Volumen, Losgröße oder Merkmalsanzahl, beschrieben werden [2]. Mit zunehmender Modellierungstiefe schließen sich analytische Kalkulationsmethoden an, bei denen die Herstellkosten verursachungsgerecht aus einzelnen Kostenbestandteilen, wie Material, Rüsten, Bearbeitungszeit, Werkzeugen und qualitätsbezogenen Aufwänden, aufgebaut werden. Innerhalb dieser analytischen Verfahren können statistische Kostenfunktionen von geometriebasierten Kostenfunktionen unterschieden werden. Während statistische Kostenfunktionen Zusammenhänge aus historischen Daten ableiten, überführen geometriebasierte Ansätze Merkmale aus CAD- oder STEP-Modellen in eine bewertbare Folge von Fertigungsschritten. Wird diese Merkmalsbeschreibung zusätzlich mit der Ableitung von Aufspannungen, Arbeitsfolgen und Operationen verknüpft, entsteht eine arbeitsplanbasierte Kalkulation, die den realen Herstellprozess deutlich präziser abbildet als rein erfahrungs- oder parameterbasierte Verfahren [2, 9].

Die höchste Modellierungstiefe wird schließlich durch CAM- und simulationsgestützte Ansätze erreicht, bei denen Bearbeitungszeiten unmittelbar aus Werkzeugwegen, NC (Numerical Control)-Informationen oder digitalen Prozessmodellen abgeleitet werden. Auf Basis der abgeleiteten Bearbeitungszeiten können die daraus resultierenden Maschinen-, Personal- und Werkzeugkosten unter Verwendung geeigneter Kostensätze transparent berechnet werden. Solche Verfahren versprechen eine hohe Prozessnähe, erfordern jedoch eine entsprechend hohe Informationsverfügbarkeit und Planungstiefe.

Neuere datengetriebene Ansätze erweitern diesen Bereich, indem sie CAM-, Geometrie- und Toleranzinformationen zur Verbesserung der Zeit- und Kostenprognose nutzen und damit die Lücke zwischen früher Angebotsphase und detaillierter Prozessabbildung verringern [10]. Für die Angebotsphase in der Zerspanspannung erscheint daher nicht ausschließlich ein Kalkulationsverfahren durchgängig ausreichend. Zweckmäßig ist vielmehr ein hybrides Vorgehen, das qualitative Vorabschätzungen mit parametrischen, analytischen und arbeitsplan- oder simulationsnahen Modellen kombiniert. Die Arbeitsplanung ist dabei das zentrale Bindeglied zwischen den technischen Bauteilanforderungen und einer belastbaren Herstellkostenkalkulation [1, 2, 7]. Voraussetzung hierfür ist, dass die relevanten technischen Anforderungen aus den verfügbaren Produktdaten maschinenlesbar in ihrem semantischen Kontext erfasst werden können.

2.2 Auslesen technischer Anforderungen

Für die automatisierte Arbeitsplanung und Kostenkalkulation müssen die technischen Anforderungen eines Bauteils zunächst aus den verfügbaren Produktdaten extrahiert werden. Für die zerspanende Lohnfertigung liegen 3D-Daten typischerweise in neutralen Austauschformaten der STEP-Anwendungsprotokolle (AP) vor. Zwischen den einzelnen APs besteht jedoch ein unterschiedlicher Informationsumfang. Während ältere Protokolle, wie AP203 und AP214, vor allem den Geometrieaustausch unterstützen, erlaubt STEP AP242 zusätzlich die Übertragung fertigungsrelevanter Produktinformationen als Product Manufacturing Information (PMI). Dazu zählen insbesondere fertigungsrelevante Angaben wie Maße, Form- und Lagetoleranzen, Oberflächenanforderungen und weitere technische Annotationen. AP242 schafft die Voraussetzung für eine proprietär unabhängige und medienbruchfreie Weitergabe fertigungsrelevanter Produktinformationen entlang der digitalen Prozesskette. Aus STEP-Modellen lassen sich geometrische Merkmale und ihre Abmessungen mit feature- und prozessbasierten Ansätzen grundsätzlich zuverlässig ableiten [5]. Damit ist in AP242 fachlich eine durchgängige maschinenlesbare Beschreibung technischer Anforderungen möglich. Ein technisches Hindernis für die Marktdurchdringung sind Export- und Importfilter etablierter CAD-CAM-Programme.

In der industriellen Praxis der Lohnfertigung ist die Nutzung von STEP AP242 mit seinem vollen Funktionsumfang noch nicht flächendeckend etabliert, sodass die technische Zeichnung weiterhin häufig das führende Informationsmedium für fertigungsrelevante Anforderungen bleibt. Aktuelle Forschungsarbeiten untersuchen daher die KI-gestützte Rückführung aus 2D-Zeichnungen extrahierter Informationen in 3D-CAD- beziehungsweise STEP-Strukturen und damit die Wiederherstellung des semantischen Zusammenhangs zwischen Annotation und Geometrie [11].

Für technische Zeichnungen ist zunächst zwischen maschinenlesbaren und rein rasterbasierten PDF-Dateien zu unterscheiden. Liegen Texte und Annotationen als echte PDF-Objekte vor, können sie zusammen mit ihrer Position auf der Zeichnung direkt aus dem Datenstrom extrahiert werden. Je nach CAD-System und gewählten Exporteinstellungen können nicht nur Texte, sondern teilweise auch Zeichnungssymbole als auswertbare Objekte erhalten bleiben. Werden die Inhalte dagegen als Grafik exportiert oder gescannte Zeichnungen weitergegeben, steht nur noch die Pixeldarstellung zur Verfügung. In diesem Fall muss die Struktur der Zeichnung durch Bildverarbeitungsalgorithmen rekonstruiert werden, bevor Zahlen, Texte, Toleranzrahmen oder Oberflächensymbole vom Computer weiterverarbeitet werden können.

Für das automatisierte Auslesen der technischen Zeichnung ist diese Unterscheidung wesentlich, weil sich der Aufwand und die Fehleranfälligkeit zwischen vektorbasierten und rasterbasierten Dokumenten deutlich unterscheiden [12, 13]. Die Rückführung von Bildinformationen rasterbasierter oder gescannter technischer Zeichnungen in maschinenlesbare Informationen erfolgt bei identischen Zeichen und Symbolen aus dem gleichen CAD-System mittels Template Matching und bei fast identischen Zeichen und Symbolen über Verfahren der optischen Zeichenerkennung (Optical Character Recognition, OCR) und der Symbolerkennung. Anders als bei Fließtext ist die Texterkennung in technischen Zeichnungen jedoch durch kurze Zeichenfolgen, Maßzahlen, Führungs- und Maßlinien, überlagerte Symbole sowie unterschiedliche Textorientierungen erschwert.

Schlagenhauf *et al.* zeigen für technische Zeichnungen, dass klassische OCR-Ansätze aufgrund der hohen visuellen Komplexität, fehlender Trainingsdaten sowie der Überlagerung von Text mit Linien und unbekannten Symbolen an Grenzen stoßen [14]. Auch aktuelle Übersichtsarbeiten betonen, dass technische Zeichnungen und Engineering-Diagramme aufgrund ähnlicher, dicht gepackter und teilweise überlappender Symbole sowie variabler Textlagen zu den anspruchsvollsten Dokumentklassen der automatisierten Digitalisierung gehören [12]. Villena Toro und Tarkian stellen einen mehrstufigen Ansatz vor, der Segmentierung, klassische OCR und Bildverarbeitung mit der nachgelagerten Nutzung von Vision-Language-Modellen kombiniert [13]. Gerade für Form- und Lagetoleranzen bleibt die robuste Symbolerkennung jedoch weiterhin eine zentrale Herausforderung, weil öffentlich verfügbare, ausreichend große und domänenspezifisch annotierte Datensätze nur in begrenztem Umfang verfügbar sind [12–14].

Im vorliegenden Projekt liegen technische Zeichnungen vor, bei denen Texte und Maßangaben maschinenlesbar im PDF gespeichert sind, während die Symbole der Form- und Lagetoleranzen als Bildelemente eingebettet sind. Für diese Randbedingung wird im Folgenden eine Methode vorgestellt, mit welcher die Erkennung und Positionsbestimmung der Symbole in technischen Zeichnungen gezielt verbessert werden kann.

3 Methodik zur verbesserten Symbolerkennung

Entsprechend dem in Bild 2 dargestellten Ablauf der Kostenmodellerstellung müssen die in technischen Zeichnungen enthaltenen Anforderungen zunächst in maschinenlesbare Merkmale überführt werden, bevor sie für Arbeitsplanung und Kostenprognose genutzt werden können. Da die Texte und Maßangaben der vorliegenden Zeichnungen direkt aus dem PDF-Datenstrom




Bild 4 Beispiel einer gelabelten technischen Zeichnung aus dem synthetischen Datensatz (links) sowie Heatmap der Symbolpositionen im Datensatz (rechts). Grafik: IFW

extrahiert werden können, besteht die zentrale methodische Herausforderung in der Erkennung und Positionsbestimmung der als Bildelemente eingebetteten Symbole. Diese Symbole enthalten fertigungsrelevante Informationen, die beispielsweise den Prüfungsaufwand, die Bearbeitungsstrategie und die Auswahl geeigneter Fertigungsmittel beeinflussen und damit kostenrelevant sein können. Zur Untersuchung der Erkennungsleistung und Generalisierungsfähigkeit der Modelle wurden insgesamt fünf Datensätze zusammengestellt, die sowohl kontrollierte synthetische Szenarien als auch reale industrielle Zeichnungen abdecken.

Zwei der Datensätze wurden synthetisch mit dem CAD-System „Siemens NX“ erzeugt. Dazu wurden technische Zeichnungen so exportiert, dass die Symbole im PDF als maschinenlesbarer Text vorliegen. Diese Information konnte dann mit der Python-Bibliothek „PyMuPDF“ ausgelesen und für die Datensatzgenerierung gezielt modifiziert werden, indem Zeichen ersetzt sowie deren Größe und Position variiert wurden. Der erste synthetische Datensatz („Synthetische Symbole“) bestand aus 1000 Zeichnungen mit leerem Zeichenblatt und Schriftfeld, in die ausschließlich die relevanten Symbole an zufälligen Positionen eingefügt wurden. Auf diese Weise konnte die Symbolerkennung zunächst ohne Einflüsse aus realer Bauteilgeometrie untersucht werden. Der zweite synthetische Datensatz („Synthetischer Datensatz Bauteil“) umfasst ebenfalls 1000 Zeichnungen eines zylindrischen Bauteils, dessen Geometrieparameter gleichverteilt variiert wurden. Zudem wurden sowohl die Position des Bauteils auf dem Zeichenblatt als auch die Positionen und der Typ der Symbole systematisch variiert. So entstand ein Datensatz, der neben den Symbolen auch geometrischen Kontext und realistischere Lagevariationen enthält. **Bild 4** zeigt exemplarisch eine technische Zeichnung mit gelabelten Symbolen aus diesem Datensatz sowie eine Heatmap der Symbolpositionen.

Neben den synthetischen Datensätzen wurden zwei reale Industriedatensätze in die Untersuchung einbezogen. Diese Datensätze bilden den in der industriellen Praxis relevanten Fall eingescannter technischer Zeichnungen ab, bei denen Verzeichnungen durch Schiefen sowie die fehlende direkte maschinelle Auslesbarkeit der Inhalte zusätzliche Herausforderungen für die Symbolerkennung verursachen. Der erste („Industriedatensatz Projektpartner“) stammt von Projektpartnern und umfasst

577 eingescannte technische Zeichnungen aus unterschiedlichen CAD-Systemen. Die zugrunde liegenden Bauteile umfassen überwiegend drehbearbeitete Funktionsbauteile sowie zugehörige Komponenten aus dem Baugruppenumfeld. Entsprechend reicht das Zeichnungsspektrum von vergleichsweise übersichtlichen Einzelteilzeichnungen bis zu stärker verdichteten Zeichnungen mit mehreren Ansichten, funktionsrelevanten Bemaßungen und zusätzlichen technischen Angaben. Da in diesen Zeichnungen keine direkt nutzbaren Positionsinformationen vorlagen, wurden die Symbole manuell gelabelt.

Der zweite reale Datensatz („Industriedatensatz Roboflow“) basiert auf einem öffentlich verfügbaren Zeichnungsdatsatz aus Roboflow Universe mit 1804 eingescannten und gelabelten technischen Zeichnungen [15]. Die Bauteile umfassen überwiegend drehbearbeitete Pumpenkomponenten, von einfachen hülsen- und flanschähnlichen Einzelteilen bis hin zu komplexeren rotations-symmetrischen Funktionsbauteilen mit integrierter Schmierstoffzuführung. Für diesen Datensatz wurden die Originalzeichnungen ohne weitere Vorverarbeitung verwendet. Da die dort vorhandenen Bounding Boxes häufig nicht nur das Symbol selbst, sondern zusätzlich Toleranzangaben enthielten, wurden die Labels automatisch angepasst. Hierzu wurde jeweils die längere Seitenkante der Bounding Box reduziert, sodass quadratische Ausschnitte entstanden. **Bild 5** zeigt eine Zeichnung aus dem Datensatz. Dabei erfolgte die Kürzung gezielt auf der rechten oder oberen Seite, weil das eigentliche Symbol innerhalb der ursprünglichen Bounding Box meist links unten liegt, während zusätzliche numerische Toleranzangaben typischerweise rechts oder oberhalb angeordnet sind.

Als fünfter Datensatz („Industriedatensatz Augmentiert“) wurde schließlich eine synthetisch erweiterte Variante des öffentlichen Industriedatensatzes [15] erzeugt. Dazu wurden in die gescannten Zeichnungen Symbole einschließlich Toleranzwert und Bezugsbuchstaben an zufälligen Positionen eingefügt und als neue Trainingsbeispiele gespeichert. Durch diese Vorgehensweise konnte ein hybrider Datensatz erzeugt werden, der reale Hintergrundstrukturen technischer Zeichnungen mit kontrolliert variierenden Symbolannotation kombiniert.

Mit der beschriebenen Datensatzstruktur werden drei unterschiedliche Anforderungsniveaus abgedeckt: erstens die isolierte



Bild 5 Beispiel einer gelabelten technischen Zeichnung aus dem Roboflow-Datensatz. *Grafik: IFW in Anlehnung an [15]*

Symbolerkennung ohne geometrischen Kontext, zweitens die Erkennung in synthetisch variierenden technischen Zeichnungen mit Bauteilgeometrie und drittens die robuste Erkennung in realen Industriezeichnungen. Dadurch lässt sich in der Evaluierung gezielt untersuchen, welchen Einfluss rein synthetische, reale und augmentierte Trainingsdaten auf die Erkennungsleistung und die Positionsbestimmung der Symbole haben.

4 Evaluierung

Zur Evaluierung der Methode wurde das Objekterkennungsmodell „YOLOv10“ von Ultralytics verwendet. Es handelt sich um ein neuronales Netz zur Objekterkennung, das Bildinhalte automatisiert lokalisiert und klassifiziert. Das Modell wurde jeweils auf einem der fünf Datensätze trainiert und anschließend auf den jeweils vier übrigen Datensätzen getestet. Ziel der Untersuchung war damit nicht die Leistungsbewertung auf bekannten Zeichnungen, sondern die Frage, wie gut sich ein trainiertes Modell auf neue Zeichnungstypen und veränderte Datenquellen übertragen lässt. Insgesamt ergeben sich daraus 20 Cross-Domain-Testläufe (5 x 4 Versuchsläufe). Als Bewertungsgröße wird im Folgenden die Erkennungsrate (Recall) verwendet. Sie gibt an, wie viele der tatsächlich vorhandenen Symbole erkannt wurden. Hohe Werte bedeuten, dass nur wenige Symbole übersehen werden. Für den vorliegenden Anwendungsfall ist diese Kennzahl besonders

relevant, da nicht erkannte Toleranzsymbole die nachgelagerte Arbeitsplanung und Kostenkalkulation unmittelbar beeinflussen können. Die **Tabelle** zeigt die Versuchsergebnisse der Testläufe für die Erkennungsrate.

Dabei wird deutlich, dass ein ausschließlich auf stark vereinfachten synthetischen Symbolbildern trainiertes Modell nur eingeschränkt auf reale technische Zeichnungen übertragbar ist. Das auf dem Datensatz „Synthetische Symbole“ trainierte Modell erreicht über alle Fremddatensätze hinweg lediglich eine mittlere Erkennungsrate von 0,18 und bildet damit den schwächsten Ansatz. Wird im Training zusätzlich geometrischer Kontext berücksichtigt, verbessert sich die Übertragbarkeit deutlich. Das auf dem synthetischen Bauteildatensatz trainierte Modell erreicht einen Mittelwert von 0,37 und übertrifft damit den rein symbolbasierten Datensatz deutlich. Höhere Werte ergeben sich für die auf realen Industriedatensätzen trainierten Modelle. Der Datensatz der Projektpartner erzielt einen Mittelwert von 0,41, während das auf dem Roboflow-Datensatz trainierte Modell auf 0,47 kommt. Die höchsten mittleren Werte ergeben sich für das auf dem augmentierten Datensatz trainierte Modell mit 0,55. Dies deutet darauf hin, dass reale Hintergrundstrukturen technischer Zeichnungen in Verbindung mit einer hinreichenden Variation von Symbolpositionen und Symbolausprägungen die besten Voraussetzungen für eine robuste Symbolerkennung schaffen. Gleichzeitig zeigt der Vergleich mit dem Datensatz der Projekt-

Tabelle Versuchsergebnisse der Testläufe für die Erkennungsrate (Recall).

Test \ Training	Synthetische Symbole	Synthetischer Datensatz Bauteil	Industriedatensatz Projektpartner	Industriedatensatz Roboflow	Industriedatensatz Augmentiert	Mittelwert
Synthetische Symbole	-	0,28	0,11	0,13	0,19	0,18
Synthetischer Datensatz Bauteil	0,47	-	0,24	0,31	0,45	0,37
Industriedatensatz Projektpartner	0,27	0,34	-	0,53	0,49	0,41
Industriedatensatz Roboflow	0,36	0,43	0,51	-	0,56	0,47
Industriedatensatz Augmentiert	0,42	0,58	0,62	0,60	-	0,55

partner, dass reale Zeichnungen allein noch nicht automatisch zur besten Generalisierung führen, wenn die Datenbasis kleiner ist oder die Variation der Symbolpositionen und Symboltypen begrenzt bleibt.

Insgesamt zeigen die Ergebnisse, dass die Generalisierungsfähigkeit der Symbolerkennung wesentlich von der Zusammensetzung des Trainingsdatensatzes abhängt, vor allem von realen Hintergrundstrukturen, variierenden Symbolpositionen, unterschiedlichen Symboltypen und vorhandenem geometrischem Kontext. Rein synthetische Daten eignen sich, um einzelne Effekte kontrolliert zu untersuchen und ein Basismodell aufzubauen. Für eine robuste Übertragbarkeit auf reale technische Zeichnungen sind jedoch reale Hintergrundstrukturen, variierende Symbolpositionen und eine hinreichende Vielfalt der Symbolausprägungen nötig. Besonders vorteilhaft erscheint daher die Kombination aus realen und gezielt synthetisch erweiterten Datensätzen, da sie die Vorteile kontrollierter Variation mit den visuellen Eigenschaften industrieller Zeichnungen verbindet.

5 Zusammenfassung und Ausblick

Der Beitrag zeigt, welche Grundlagen für eine automatisierte Herstellkostenkalkulation in der Zerspanung geschaffen werden müssen. Da technische Zeichnungen in der industriellen Praxis weiterhin eine zentrale Informationsquelle sind, ist insbesondere das maschinenlesbare Auslesen von Maßen, Texten und Symbolen eine wesentliche Voraussetzung für die weitere Automatisierung der Arbeitsplanung und Kostenprognose. Für Zeichnungen mit identischen Symbolen aus gleichartigen CAD-Exporten kann Template Matching geeignet sein. Bei variierenden Symbolschriftarten, unterschiedlichen Exporteinstellungen oder eingescannten Zeichnungen ist die Übertragbarkeit aber begrenzt. Die vorgestellte Methodik zeigt, dass die Erkennungsleistung in solchen Fällen durch geeignet zusammengestellte synthetische, reale und augmentierte Datensätze gezielt verbessert werden kann.

Damit wurde die Grundlage geschaffen, um im nächsten Schritt Prognosen der Herstellkosten abzuleiten. Im Fokus stehen hierbei Unsicherheiten im Rahmen der Kostenprognose. Perspektivisch können so neben einem erwarteten Kostenwert auch Wahrscheinlichkeitsbereiche und Vorhersageintervalle der Herstellkosten angegeben werden, um eine transparente Entscheidungsgrundlage für Angebotspreise zu schaffen.

FÖRDERHINWEIS

Die Arbeiten wurden im Rahmen des Projekts „SzenoKalk“ durch das Bundesministerium für Wirtschaft und Energie (BMWE) gefördert (Förderkennzeichen: 01IF23393N).

DANKSAGUNG

Die Autoren bedanken sich für die finanzielle Förderung des Forschungsprojektes. Ein großer Dank gilt ebenfalls den Unterstützern up2parts, 4cost und Siemens Digital Industries Software.

Literatur

[1] García-Crespo, Á.; Ruiz-Mezcua, B.; López-Cuadrado, J. L. et al.: A review of conventional and knowledge based systems for machining price quotation. Journal of Intelligent Manufacturing 22 (2011) 6, pp. 823–841

[2] Niazi, A.; Dai, J. S.; Balabani, S. et al.: Product cost estimation: technique classification and methodology review. Journal of Manufacturing Science and Engineering 128 (2006) 2, pp. 563–575

[3] Eversheim, W.: Organisation in der Produktionstechnik 3: Arbeitsvorbereitung. Heidelberg: Springer 2002

[4] Ning, F.; Qu, H.; Shi, Y. et al.: Feature-Based and Process-Based Manufacturing Cost Estimation. Machines 10 (2022) 5, #319

[5] Lorenzen, L. E.: Entwicklung einer Methode zur gentelligenten Arbeitsplanung. Berichte aus dem IFW, Band 4/2012. Hannover: PZH Verlag 2012

[6] Hussong, M.; Ruediger-Flore, P.; Klar, M. et al.: Selection of manufacturing processes using graph neural networks. Journal of Manufacturing Systems 80 (2025), pp. 176–193

[7] Schwabe, O.; Shehab, E.; Erkoyuncu, J. A.: An Approach for Selecting Cost Estimation Techniques for Innovative High Value Manufacturing Products. Procedia CIRP 55 (2016), pp. 41–46

[8] Tlija, M.; Letaief, M. B.; Louhichi, B.: CAD Comparison Model For Data Reuse And Manufacturing Cost Estimation. Procedia CIRP 70 (2018), pp. 59–65

[9] Han, J.; Kang, M.; Choi, H.: STEP-based feature recognition for manufacturing cost optimization. Computer-Aided Design 33 (2001) 9, pp. 671–686

[10] Ma’ruf, A.; Thoriq, D. A.; Buwana, K. S.: An Early Machining Time Estimation for Make-to-Order Manufacturing Using Machine Learning Approach. Procedia CIRP 130 (2024), pp. 106–111

- [11] Grieshammer, M.; Kellner, P.; Götz, M. et al.: KI als Brücke zwischen technischer Zeichnung und CAD-Modell. *Maschinenbau* 5 (2025), S. 10–13
- [12] Jamieson, L.; Moreno-García, C. F.; Elyan, E.: A review of deep learning methods for digitisation of complex documents and engineering diagrams. *Artificial Intelligence Review* 57 (2024), #136
- [13] Villena Toro, J.; Tarkian, M.: Optimizing Text Recognition in Mechanical Drawings: A Comprehensive Approach. *Machines* 13 (2025) 3, #254
- [14] Schlagenhauf, T.; Netzer, M.; Hillinger, J.: Text Detection on Technical Drawings for the Digitization of Brown-field Processes. *Procedia CIRP* 118 (2023), pp. 372–377
- [15] Deep Learning Projects: Roboflow Universe. Symbols. Stand: Internet: universe.roboflow.com/deep-learning-projects-atwen/symbols-l8rn4. Zugriff am: 21.04.2026

Prof. Berend Denkena 

Dr.-Ing. Klaas Maximilian Heide 

Marcus Nein, M.Eng.

nein@ifw.uni-hannover.de

Leibniz Universität Hannover
Institut für Fertigungstechnik
und Werkzeugmaschinen IFW
An der Universität 2, 30823 Garbsen
www.ifw.uni-hannover.de

LIZENZ



Dieser Fachaufsatz steht unter der Lizenz Creative Commons
Namensnennung 4.0 International (CC BY 4.0)