

Zustandsspezifische Modelle zur universellen Prozessüberwachung

Modellbasierte Überwachung von Fräsprözessen

M. Mau, A. Puchta, J. Fleischer

ZUSAMMENFASSUNG Die datenbasierte Prozessüberwachung ermöglicht es, Fräsprözesse präzise zu analysieren und Anomalien frühzeitig zu erkennen – ohne zusätzliche Sensorik nachrüsten zu müssen. Durch den Einsatz spezialisierter Signalvorhersagemodelle und selbstlernender Mechanismen lassen sich variierende Produktionsbedingungen effizient abbilden, wodurch die Gesamtanlageneffektivität und Fertigungsqualität in Produktionsumgebungen mit hoher Variantenvielfalt gesteigert werden können.

STICHWÖRTER

Fräsen, Werkzeugmaschinen, Digitalisierung

Condition-specific models for universal process monitoring – Model-based monitoring of milling processes

ABSTRACT Data-based process monitoring makes it possible to precisely analyze milling processes and detect anomalies at an early stage – without the need to retrofit additional sensors. By using specialized models and self-learning mechanisms, varying production conditions can be efficiently mapped, thereby increasing overall equipment effectiveness and manufacturing quality in production environments with a high number of variants.

1 Einleitung

Der demografische Wandel und die damit verbundenen Engpässe an Fachkräften [1] stellen Unternehmen vor die dringende Aufgabe, ihre Produktionsprozesse sowie die Digitalisierung dieser Prozesse effizienter zu gestalten, um mit sinkendem Personaleinsatz weiterhin eine hohe Produktivität zu erreichen [2; 3]. Bei gleichbleibender Anzahl an Produktionsmaschinen sieht sich das Fachpersonal zunehmend mit einer wachsenden Anzahl zu überwachenden Maschinen konfrontiert. Die steigende Komplexität der Produktionsumgebung erhöht dabei das Risiko von Fehlern und verlängerten Ausfallzeiten [4]. Gleichzeitig erfordert die wachsende Nachfrage nach individualisierten Produkten und die immer kürzer werdenden Lebenszyklen von Produkten, dass Werkzeugmaschinen und ihre Überwachungsmodelle flexibel auf sich ändernde Produktionsanforderungen reagieren können [4]. Werden Anomalien in Fräsprözessen (Werkzeugbruch, Verschleiß, Materialunregelmäßigkeiten etc.) erst spät detektiert, reduzieren sich die Handlungsmöglichkeiten des Fachpersonals (Werkzeugwechsel, Abbruch des Fertigungsprozesses). Insbesondere bei komplexen Werkstücken mit einer langen Bearbeitungsdauer kann dies zu hohen Ausschusskosten führen.

Um diesen Herausforderungen zu begegnen, sind präzise Systeme zur Prozessüberwachung unverzichtbar. Sie tragen dazu bei, unvorhergesehene Störungen und Ausschuss zu minimieren, wodurch die Gesamtanlageneffektivität (Overall Equipment Effectiveness, OEE) entscheidend verbessert werden kann.

Damit Überwachungssysteme auch an Bestandsmaschinen im Brownfield kostengünstig implementiert werden können, ist es vorteilhaft, wenn hierzu keine zusätzliche kostspielige Sensorik

nachgerüstet werden muss, sondern auf vorhandene Maschinen Daten zurückgegriffen werden kann. Insbesondere die Motorströme der Hauptspindel- und Vorschubachsenantriebe eignen sich für eine Überwachung, da viele prozessbestimmende Faktoren wie Prozesskraft, Drehmoment und Werkzeugverschleiß die Höhe der Ströme beeinflussen [5]. Je nach Maschinentyp und Steuerung lassen sich die Motorströme direkt aus der Steuerung auslesen. Ist dies nicht möglich, beispielsweise bei alten Bestandsmaschinen, kann ein Strommesssystem kostengünstig mit Stromwandlern nachgerüstet werden [6].

2 Ansätze zur Prozessüberwachung

Klassische Verfahren der statistischen Prozesskontrolle basieren auf der Auswertung von Referenzwerten aus Stichproben identisch gefertigter Bauteile. In einer modernen Produktionsumgebung mit niedrigen Stückzahlen – bis hin zur Losgröße 1 – eignet sich dieser Ansatz aufgrund der fehlenden Referenzwerte nicht mehr. Viele erforschte Ansätze zur flexibleren Prozessüberwachung basieren auf der Integration zusätzlicher Sensorik wie einer Kraftmessplattform, Vibrationssensoren oder Kameras in der Maschine [7, 8, 9]. Die Anschaffung und Integration dieser Sensorik ist allerdings mit Kosten verbunden. Es existieren Ansätze zur Vorhersage des Energieverbrauchs der Motoren für die Fahrt einzelner Sätze auf Basis des G-Codes [10; 11]. Kurze Abweichungen im Stromverbrauch, wie das Fräsen durch einen Lunker, fallen mit diesem Ansatz nicht auf.

Aktuelle Forschungsansätze zielen darauf ab, Referenzwerte auf wiederkehrende geometrische Merkmale wie Taschen oder Nuten zurückzuführen [12]. Eine Überwachung, die unabhängig




Bild 1. Beispielhafte Darstellung der Gültigkeitsbereiche einzelner Modelle. Modell A ist auf die Vorhersage des Motorstroms der X-Achse bei hohen Vorschubgeschwindigkeiten spezialisiert, während Modell B bessere Ergebnisse für niedrigere Geschwindigkeiten liefert. Der untere Graph zeigt den Vorhersagefehler der einzelnen Modelle. *Grafik: KIT wbk*

von vorher gefertigten Werkstücken oder Konstruktionsmerkmalen funktioniert, setzt jedoch die Möglichkeit voraus, Referenzwerte für jeden Messzeitpunkt mit hoher zeitlicher Auflösung vorherzusagen.

Ansätze, bei denen Überwachungsmodelle durch gezielte Datenerhebung via Experimenten parametrisiert werden, haben signifikante Nachteile: Sie beanspruchen kostbare Maschinenzeit, reduzieren die OEE und führen zu erhöhtem Verbrauch an Material und Energie. In agilen Produktionsumgebungen, die durch stark individualisierte Produkte und kleine Losgrößen gekennzeichnet sind, ist das Sammeln solcher Datensätze für jede neue Produktvariante weder praktikabel noch effizient. Deshalb sind unter diesen Bedingungen neue, innovative Modellierungsstrategien erforderlich, um eine effektive Prozessüberwachung zu gewährleisten.

Ströbel präsentiert einen Ansatz, Motorströme während eines Fräspannisses in hoher zeitlicher Auflösung vorherzusagen [13]. Durch die hohe zeitliche Auflösung können konstante Anomalien, wie ein erhöhter Energiebedarf durch ein verschlissenes Werkzeug, von kurzen Anomalien, wie dem Fräsen durch einen Lunker, detektiert und voneinander abgegrenzt werden. Hierzu werden zunächst die Prozesskräfte und Materialabtragsrate unter Verwendung des G-Codes und der Werkstückgeometrie mithilfe einer Abtragssimulation berechnet. Diese berechneten Werte werden mit der Geschwindigkeit und Beschleunigung genutzt, um datengetriebene Modelle auf Basis von Maschinellen Lernen zu bilden.

$$Daten_{ein} = \left(\begin{array}{l} \text{Geschwindigkeit}_{X, Y- \text{ und } Z\text{-Achse, Hauptspindel}} \\ \text{Beschleunigung}_{X, Y- \text{ und } Z\text{-Achse, Hauptspindel}} \\ \text{Kraft}_{X, Y- \text{ und } Z\text{-Achse, Hauptspindel}} \\ \text{Materialabtragsrate} \end{array} \right) \quad Daten_{aus} = (\text{Motorstrom}_i)$$

Gleichung 1: Ein- und Ausgangssignale der datenbasierten Stromsignalvorhersage nach Ströbel. Für jeden Motor der Vorschubachsen beziehungsweise Hauptspindel wird ein Modell gebildet. Die Eingangssignale der Modelle enthalten auch die

Signale der anderen Achsen, damit das Modell Quereinflüsse berücksichtigen kann.

Die Implementierung nach Ströbel ermöglicht bereits eine Vorhersage der Motorströme während eines Fräspannisses, indem ein auf zuvor aufgezeichneten Daten trainiertes Modell verwendet wird. Dieses Modell liefert besonders dann zuverlässige Ergebnisse, wenn die Materialien und Werkstücke eine gewisse Ähnlichkeit aufweisen. In hochflexiblen Produktionsumgebungen, in denen eine große Bandbreite unterschiedlicher Werkstücke aus verschiedenen Werkstoffen und unter Verwendung verschiedenster Werkzeuge gefertigt wird, stoßen solche Ansätze jedoch an ihre Grenzen. Ein einzelnes Modell, das mit Daten aus stark variierenden Fertigungsprozessen trainiert wurde, benötigt eine hohe Komplexität, um alle möglichen Szenarien abzudecken. Dies kann die Generalisierungsfähigkeit des Modells erheblich einschränken, sodass neue Prozesse, für die es keine vergleichbaren Trainingsdaten gibt, ungenau vorhergesagt werden.

3 Erweiterung bestehender Modelle

Eine vielversprechende Alternative ist die Verwendung mehrerer spezialisierter Regressionsmodelle zur Stromvorhersage, die jeweils auf spezifische Prozessbereiche fokussiert sind. Diese Modelle besitzen keine globalen Gültigkeitsbereiche, die alle möglichen Werte der Prozessparameter umfassen, sondern arbeiten innerhalb klar definierter lokaler Bereiche. Dadurch kann jedes Modell spezifische Prozesse mit höherer Genauigkeit vorhersagen.

Ein anschauliches Beispiel für die Kombination mehrerer Modelle mit begrenztem Gültigkeitsbereich ist die Unterscheidung zwischen dem normalen Fräspanniss und Bewegungen der Maschine im Eilgang. **Bild 1** verdeutlicht dies. Für das Training von Modell A wurden Datenpunkte aus dem Datensatz [14] während hoher Vorschubgeschwindigkeit verwendet, während für das Training von Modell B Datenpunkte mit niedrigerer Vorschubgeschwindigkeit

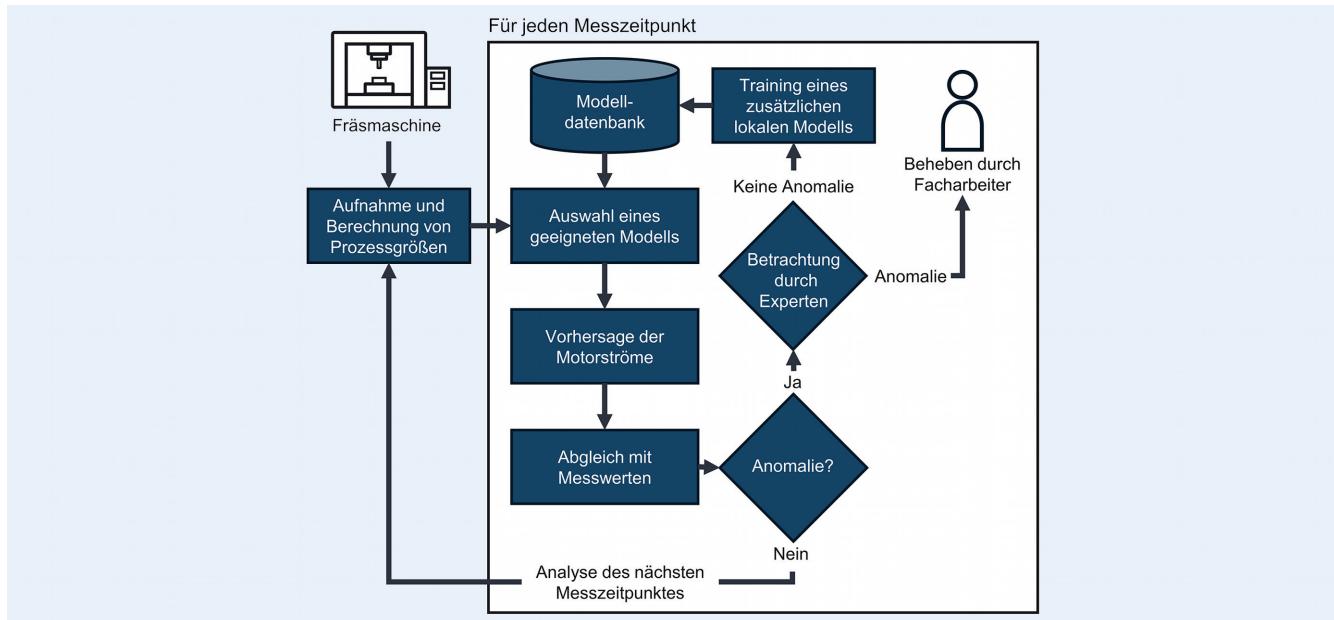


Bild 2. Informationsflussdiagramm des selbstlernenden Prozessüberwachungssystems. *Grafik: KIT wbk*

genutzt wurden. Dies hat zur Folge, dass Modell A den Motorstrom während einer Fahrt im Eilgang bedeutend präziser vorhersagen kann als Modell B. Während des Fräsprozesses ist ein gegenläufiger Effekt zu beobachten. Weder Modell A noch Modell B können den gesamten Prozess adäquat abbilden. Nutzt ein Gesamtsystem beide Modelle jeweils in dem Bereich, für den die Modelle gebildet wurden, kann eine deutlich bessere Stromvorhersage erreicht werden.

Die Verwendung der Vorschubgeschwindigkeit ist nur ein Beispiel, möglich sind auch andere Prozessgrößen beziehungsweise Kombinationen dieser, wie Beschleunigung, Prozesskräfte oder die Materialabtragsrate.

3.1 Selbstlernende Prozessanpassung

Damit sich das Prozessüberwachungssystem selbstständig an neue Prozesse anpassen kann, ist ein selbstlernender Aspekt erforderlich. Die grundlegende Funktionsweise eines solchen Systems ist in **Bild 2** dargestellt. Nachdem für jeden Messpunkt aus den Maschinendaten die Prozesskräfte und Materialabtragsrate berechnet wurden, wird ein passendes Regressionsmodell ausgewählt. Dies geschieht durch die Auswahl des Modells, dessen Definitionsbereich bestmöglich zu den Werten der Prozessgrößen des Messpunktes passt. Unter Verwendung des ausgewählten Modells werden die Motorströme der Maschine vorhergesagt und mit den gemessenen Stromwerten verglichen. Wird aufgrund der Differenz zwischen den vorhergesagten Strömen und den gemessenen Strömen aus den Maschinendaten eine Anomalie vermutet, wird der Fräsprozess von einem Facharbeiter überprüft. Wenn die Anomalie tatsächlich auf einen Prozessfehler (zum Beispiel Lunker im Werkstück, Werkzeugverschleiß) zurückzuführen ist, können entsprechende Maßnahmen eingeleitet werden. Liegt hingegen kein Fehler vor, muss das System angepasst werden, um die Vorhersagegenauigkeit zu verbessern.

Ein zentrales Element des selbstlernenden Ansatzes ist die Bildung neuer lokaler Modelle. Diese Modelle werden gezielt für Prozesse erstellt, die von bestehenden Modellen nicht präzise abgebildet werden können. Ein Algorithmus analysiert die relevanten Prozessgrößen und definiert aus diesen einen Gültigkeitsbereich, der von keinem existierenden Modell abgebildet wird. Die Datenpunkte in diesem Bereich werden dann zum Training eines neuen lokalen Modells verwendet. Zukünftige Vorhersagen innerhalb dieses Bereichs werden dann von dem lokalen Modell übernommen, wodurch die Vorhersagequalität in diesem Bereich signifikant verbessert wird. Je länger das System in einem variantenreichen Produktionsumfeld eingesetzt wird, desto mehr lokale Modelle werden in der Modelldatenbank abgespeichert. Hierdurch können auch bei neuen Produktionsprozessen schnell präzise Vorhersagen der Motorströme getroffen und hierdurch eine Prozessüberwachung realisiert werden. Im Gegensatz zum Online Machine Learning, bei dem alle neu erfassten Datenpunkte unmittelbar zur Anpassung des Modells verwendet werden, werden in diesem Ansatz ausschließlich jene Datenpunkte herangezogen, bei denen das bestehende Modell keine zufriedenstellende Vorhersage liefert. Dadurch wird gewährleistet, dass ein allmählicher Werkzeugverschleiß nicht als Normalzustand erlernt wird, sondern als Anomalie erkannt wird.

3.2 Technische Voraussetzungen

Damit ein Einsatz des modellbasierten Überwachungssystems wirtschaftlich eingesetzt werden kann, müssen Training und Einsatz der Modelle dateneffizient auf gängigen Industrie-PCs möglich sein. Die **Tabelle** gibt einen Überblick über die wesentlichen technischen Parameter der Trainingsphasen für die Modelle A und B aus Bild 1. Als Hardware wurde ein Prozessor des Typs „Intel Core i7-1360P“ eingesetzt, als Modellarchitektur wurden Extra-Trees mit 100 Estimators verwendet [15].

Tabelle. Übersicht der Datensatzgröße, Trainingsdauer und Modellgröße für Modelle A und B aus Bild 1.

	Modell A	Modell B
Trainingsdatensatz	1,5 KB	42 KB
Trainingsdauer	0,04 s	0,12 s
Modellgröße	465 KB	11,3 MB

Entsprechend den Werten aus der Tabelle lässt sich abschätzen, dass auch deutlich komplexe Gesamtsysteme mit einer Vielzahl einzelner, vergleichbarer Modelle auf gängigen Industrie-PCs problemlos eingesetzt werden können.

3.3 Vermeidung von Überanpassung

Ein potenzielles Risiko bei der Bildung von lokalen Modellen ist die Überanpassung (engl. Overfitting) durch immer kleiner werdende Gültigkeitsbereiche. Solche hoch spezialisierten Modelle könnten die Generalisierungsfähigkeit des Gesamtsystems beeinträchtigen. Um dem entgegenzuwirken, muss die Größe der Gültigkeitsbereiche begrenzt werden. Ziel ist es, eine Balance zwischen der Genauigkeit der Modellvorhersagen und der Breite der abgedeckten Prozessbereiche zu finden. Neue Modelle sollten daher nur dann gebildet werden, wenn sie einen klaren Mehrwert für die Gesamtleistung des Systems bieten.

Ein optimal konfiguriertes System nutzt die Vorteile sowohl globaler als auch lokaler Modelle. Globale Modelle bieten eine grundlegende Abdeckung über alle Prozesse hinweg, während lokal definierte Modelle spezifische Prozesse präzise adressieren. Entsprechend der Prozessgrößen wird nach einem auf die vorliegenden Werte spezialisierten lokal gültigen Modell gesucht. Existiert ein solches Modell, wird dieses verwendet, um die Motorströme mit bestmöglicher Präzision vorherzusagen. Umfasst kein Definitionsbereich der vorhandenen lokal gültigen Modelle die Prozessgrößen einer Aufnahme, wird ein global gültiges Modell genutzt, wobei davon ausgegangen wird, dass die Vorhersage eine geringere Präzision als die eines spezialisierten Modells erreicht. Die aufgenommenen Daten werden dann für die Bildung eines neuen, lokal gültigen Modells verwendet.

Durch diese Kombination wird eine effektive und effiziente Prozessüberwachung ermöglicht, die sich flexibel an neue Anforderungen anpassen kann.

4 Zusammenfassung und Ausblick

Die vorgestellten Ansätze bieten eine Grundlage, um ein selbstlernendes Prozessüberwachungssystem zu entwickeln, das sich an die Anforderungen variabler und flexibler Produktionsumgebungen anpasst. Durch die Kombination von datengetriebenen Modellen mit auf bestimmte Definitionsbereiche spezialisierten Modellen können Vorhersagen für unterschiedliche Prozessbereiche präzisiert werden, ohne dass umfangreiche manuelle Anpassungen notwendig sind.

Ein entscheidender Aspekt ist die kontinuierliche Anpassung des Systems an neue Prozesse. Hierfür ist es notwendig, dass das System Anomalien zuverlässig erkennt, durch Anwenderfeedback bewertet und durch den Einsatz neuer Daten weiterentwickelt werden kann. Der Fokus liegt darauf, eine Balance zwischen

Präzision und Generalisierungsfähigkeit zu finden, um eine nachhaltige Leistungsfähigkeit des Gesamtsystems sicherzustellen.

Langfristig hat das Konzept das Potenzial, die Prozessüberwachung nicht nur präziser, sondern auch effizienter zu machen. Besonders in hochflexiblen Produktionsumgebungen kann ein solches System dazu beitragen, Ausschuss und Ausfallzeiten zu reduzieren, die Produktionsqualität zu steigern und den Ressourcenverbrauch zu senken. Gleichzeitig könnte der Ansatz auch für andere Fertigungsprozesse weiterentwickelt werden, wodurch er über die reine Fräsprozessüberwachung hinaus Einsatzmöglichkeiten bietet.

Der vorgestellte Ansatz soll in den nächsten Schritten anhand realer Produktionsprozesse validiert und in ein funktionsfähiges System übertragen werden.

LITERATUR

- [1] Peichl, A.; Sauer, S.; Wohlrabe, K.: Fachkräftemangel in Deutschland und Europa – Historie, Status quo und was getan werden muss. ifo Schnelldienst Nr. 10 (2022), S. 70–75
- [2] Gönnheimer, P.; Netzer, M.; Lange, C. et al.: Datenaufnahme und -verarbeitung in der Brownfield-Produktion: Studie zum Stand der Digitalisierung und bestehenden Herausforderungen im Produktionsumfeld. Zeitschrift für wirtschaftlichen Fabrikbetrieb 117 (2022) 5, S. 317–320
- [3] Samochowiec, J.; Bauer, J.; Neumüller, K.: Strategies for dealing with the labour shortage – An overview. SSRN Journal (2023)
- [4] Hadad, Y.; Keren, B.: A revised method for allocating the optimum number of similar machines to operators. International Journal of Productivity and Performance Management 65 (2016) 2, pp. 223–244
- [5] Abellán-Nebot, J. V.; Romero Subirón, F.: A review of machining monitoring systems based on artificial intelligence process models. The International Journal of Advanced Manufacturing Technology 47 (2010) 1–4, pp. 237–257
- [6] Hansjosten, M.; Bott, A.; Puchta, A. et al.: Model-Based Diagnosis of Feed Axes with Contactless Current Sensing. In: Liewald, M.; Verl, A.; Bauernhansl, T.; Möhring, H.-C. (Hrsg.): Production at the Leading Edge of Technology. Lecture Notes in Production Engineering. Cham: Springer International Publishing (2023), pp. 314–323
- [7] Mohanraj, T.; Kirubakaran, E. S.; Madheswaran, D. K. et al.: Review of advances in tool condition monitoring techniques in the milling process. Measurement Science and Technology 35 (2024) 9, pp. 092002.
- [8] Möhring, H.-C.; Litwinski, K. M.; Gümmer, O.: Process monitoring with sensory machine tool components. CIRP Annals 59 (2010) 1, pp. 383–386
- [9] Xi, T.; Benincá, I. M.; Kehne, S. et al.: Tool wear monitoring in roughing and finishing processes based on machine internal data. The International Journal of Advanced Manufacturing Technology 113 (2021) 11–12, pp. 3543–3554
- [10] Brillinger, M.; Wuwer, M.; Abdul Hadi, M. et al.: Energy prediction for CNC machining with machine learning. CIRP Journal of Manufacturing Science and Technology 35 (2021), pp. 715–723
- [11] Schmitt, A.-M.; Miller, E.; Engelmann, B. et al.: G-code evaluation in CNC milling to predict energy consumption through Machine Learning. Advances in Industrial and Manufacturing Engineering 8 (2024), pp. 100140
- [12] Netzer, M.; Bach, J.; Puchta, A. et al.: Process Segmented based Intelligent Anomaly Detection in Highly Flexible Production Machines under Low Machine Data Availability. Procedia CIRP 107 (2022), pp. 647–652
- [13] Ströbel, R.; Probst, Y.; Deucker, S. et al.: Time Series Prediction for Energy Consumption of Computer Numerical Control Axes Using Hybrid Machine Learning Models. Machines 11 (2023) 11, pp. 1015
- [14] Ströbel, R.; Mau, M.; Hafez, K. et al.: Training and validation dataset 3 of milling processes for time series prediction. Karlsruher Institut für Technologie (2024)
- [15] Geurts, P.; Ernst, D.; Wehenkel, L.: Extremely randomized trees. Machine Learn 63 (2006) 1, pp. 3–42



M a r c u s M a u , M . S c . 

marcus.mau@kit.edu

Tel. +49 15239502639

Foto: KIT wbk

A l e x a n d e r P u c h t a , M . S c . 

P r o f . D r . - I n g . J ü r g e n F l e i s c h e r 

Karlsruher Institut für Technologie (KIT)

wbk – Institut für Produktionstechnik

Rintheimer Querallee 2, 76131 Karlsruhe

www.wbk.kit.edu

L I Z E N Z



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