

Schwingungsbasierte Maschinendiagnose an Vorschubachsen von Werkzeugmaschinen

Florian Lindner¹, Christian Brecher², Wieland Klein³

¹ Werkzeugmaschinenlabor (WZL) der RWTH Aachen, 52066 Aachen, E-Mail: f.lindner@wzl.rwth-aachen.de

² Werkzeugmaschinenlabor (WZL) der RWTH Aachen, 52066 Aachen, E-Mail: c.brecher@wzl.rwth-aachen.de

³ Heinrich Georg GmbH Maschinenfabrik, 57223 Kreuztal, E-Mail: wieland.klein@georg.com

Einleitung

Der hohe Grad an Wettbewerb in allen Bereichen des Werkzeugmaschinenbaus führt dazu, dass die verbauten Peripheriesysteme und Maschinenkomponenten einer ständigen Weiterentwicklung und Verbesserung unterliegen. Dies umfasst nicht nur Designverbesserungen, sondern auch den Einsatz intelligenter Diagnosesysteme zur Verbesserung der Zuverlässigkeit und der Prozessqualität [1]. Das übergeordnete Ziel beim Einsatz solcher Diagnosesysteme ist die nachhaltige Steigerung der Anlagenverfügbarkeit durch eine sichere, zuverlässige und planbare Gestaltung des ganzen Produktionsprozesses [2]. Dies ist insbesondere vor dem Hintergrund optimierter, zustandsorientierter Instandhaltung von Bedeutung, welche bei korrekter Auslegung in der Lage ist, die Produktionskosten durch die Reduzierung kostenintensiver Anlagenstillstände zu senken. Während der letzten Jahre ist das Bewusstsein hierfür sowohl bei den Anwendern von Werkzeugmaschinen als auch bei deren Herstellern stetig gewachsen, so dass bei Investitionsentscheidungen die Lebenszykluskosten (Life Cycle Costs, LCC) eine immer wichtigere Rolle spielen [3]. Am Werkzeugmaschinenlabor (WZL) der RWTH Aachen werden daher Methoden und Prozesse entwickelt, welche es in Zukunft ermöglichen sollen, den Zustand von Maschinenkomponenten anhand von Sensorsignalen zu bestimmen. Eine besondere Bedeutung hat hierbei die Analyse von Schwingungssignalen, die in diesem Beitrag anhand zweier Beispiele für einen Führungswagen einer Vorschubachse behandelt wird.

Schmierungsüberwachung mittels Frequenzbandsumme

Neben Überlast (z.B. durch Kollision), Verunreinigungen [4] oder Pittings stellt bei wälzenden Maschinenkomponenten die unzureichende Schmierung eine häufig vorkommende Ausfallursache dar [5]. Diese kann z.B. durch beschädigte Dichtungen oder falsche Wartung hervorgerufen werden. Durch den sich einstellenden metallischen Kontakt der Wälzpartner kann es zu einem starken Verschleiß und Folgefehlern wie Korrosion oder Ausbrüchen in der Laufbahn kommen. Abbildung 1 zeigt die Verhältnisse im Kontaktbereich für diesen Fall. Aufgrund der stochastischen Verteilung der Rauigkeitsspitzen und deren daraus resultierendem variablen Abstand zueinander kommt es bei Mangelschmierung zu einer breitbandigen Schwingungsanregung. Hierdurch bedingt schwingt der Führungswagen bevorzugt mit seinen Eigenfrequenzen.




Abbildung 1: Berührung der Rauigkeitsspitzen der Wälzpartner aufgrund unzureichender Schmierung. Durch die Gleitanteile beim Abwälzen kommt es zu einer breitbandigen Schwingungsanregung.

Dies ermöglicht die Überwachung des Schmierungszustands von Linearführungen und ähnlichen Komponenten, indem mittels eines geeigneten Sensors bei konstanter Verfahrgeschwindigkeit v die Beschleunigung aufgezeichnet wird. Das Zeitsignal kann anschließend mittels schneller Fouriertransformation (Fast Fourier Transform, FFT) in den Frequenzbereich überführt werden. Die Aufsummierung der Amplituden des Frequenzbereichs, in dem die Eigenschwingungen liegen, liefert dann einen einfachen Kennwert, der die Unterscheidung des Schmierungszustands ermöglicht (vgl. Abbildung 2).

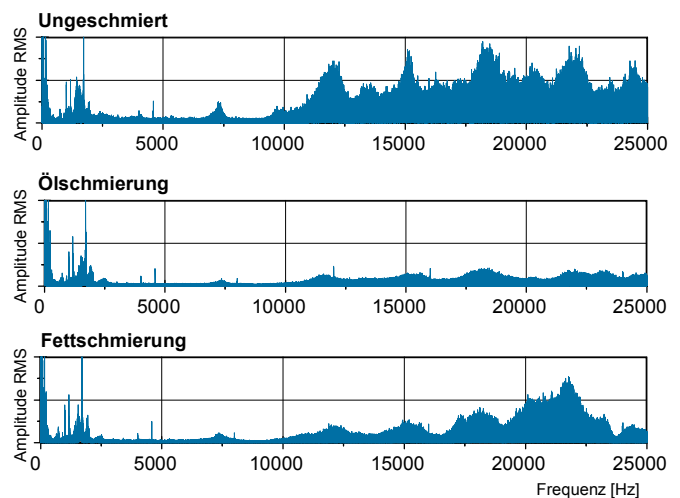


Abbildung 2: Vergleich der Spektren eines Führungswagens ($v=2\text{m/min}$, Last $F=5\text{kN}$) für den ungeschmierten Zustand sowie für Öl- und Fettschmierung.

Vergleichende Untersuchungen in Form von Simulationen des Schwingungsverhaltens und Frequenzgangmessungen am Führungswagen haben dabei die Vermutung bestätigt, dass die vor allem im ungeschmierten Zustand stark hervortretenden Signalspitzen im Bereich der Eigenfrequenzen liegen. Eine aus rechentechnischer Sicht interessante Alternative zur FFT liegt in der Betrachtung der Koeffizienten einzelner Pakete einer Wavelet-Paket-Analyse. Dieses Vorgehen liefert ähnliche Ergebnisse, auch wenn hierdurch keine Einzelfrequenzen unterschieden werden können.

Pitting-Detektierung durch Wavelet-Analyse und künstliche neuronale Netze (KNN)

Ausbrüche und Pittings stellen einen häufigen Schadensfall dar, wobei sich deren genaue Ursache häufig nur schwer feststellen lässt, da sowohl Ermüdung, Verschleiß als auch Mangelschmierung zu diesem Schadensbild führen können. Ein Ausfall des Systems Führungswagen-Führungsschiene tritt bereits dann ein, wenn die Genauigkeit der Bearbeitung unzulässig abnimmt. Da die Anzahl der Pittings mit der Zeit zunimmt, stellt eine frühzeitige Erkennung einen möglichen Lösungsansatz dar. Untersuchungen am Führungswagen haben jedoch gezeigt, dass die direkte Erkennung in Frequenzspektren nur schwer möglich ist, da durch die kurze Baulänge des Führungswagens lediglich eine geringe Anregungsenergie in das System eingebracht wird. Aufgrund der linearen Bewegung ist die Anregung darüber hinaus transient und unterscheidet sich somit grundlegend von rotierenden Lagern. Eine Alternative stellt daher die Analyse des Zeitsignals mittels Wavelet-Analyse dar, da sich Wavelets deutlich besser auf transiente Signale anwenden lassen. Hierzu wird der Effektivwert (Root Mean Square, RMS) der Koeffizienten jedes Pakets eines bis zu einem bestimmten Detail-Level zerlegten Signals gebildet. Dies erfolgt für einen Referenzfall sowie verschiedene Schadensfälle, wobei jeweils mehrere Messungen vorliegen müssen. Die vorhandene Datenmenge wird einer Signifikanzbewertung unterworfen, um lediglich die Werte zu identifizieren, die gegenüber dem Referenzzustand eine eindeutige Änderung aufweisen (vgl. Abbildung 3).




Abbildung 3: Signifikanzbewertung durch Vergleich der Verteilung des RMS verschiedener Wavelet-Pakete gegenüber dem Referenzzustand.

Auf diese Weise lassen sich zu berücksichtigenden Pakete so stark reduzieren, dass sich sinnvolle Eingangsvektoren zum Training eines KNN aufstellen lassen. In Versuchen war es nach der Lernphase des KNN möglich, in einer Werkzeugmaschine des Typs EMCO E900 intakte von

defekten Schienen zu unterscheiden. Die defekten Schienen wurden hierzu mittels eines Körnerschlags präpariert, um einen Ausbruch zu simulieren.

Zukünftige Ansätze

So vielversprechend die gezeigten Beispiele auch sein mögen, ist einschränkend zu sagen, dass es sich lediglich um Stichversuche an einer ausgewählten Baugröße handelt. Statistisch abgesicherte Untersuchungen die alle Randbedingungen und Fragestellungen abdecken sind aber ohnehin nur unter enormem Kosten- und Zeitaufwand möglich, da für die Untersuchungen Komponenten aktiv zerstört werden müssen. Dies ist weder praktikabel noch erfüllt es eine der wesentlichen Anforderungen an ein Diagnosesystem: eine Reduzierung der LCC. Zu den relevanten Themen zählen in diesem Zusammenhang unter anderem:

- Skalierbarkeit auf andere Baugrößen
- Übertragbarkeit zwischen verschiedenen Maschinen gleichen Typs (Fertigungs- und Montagetoleranzen) sowie zwischen ähnlichen Maschinenkomponenten (Rollen- zu Kugelführungen)
- Physikalische Randbedingungen (Toleranzen, Oberflächenrauheit, Masse, Temperatur, etc.)

Es wäre daher zu überlegen, ob nicht auf Basis physikalischer, mechanischer und akustischer Modelle viele der oben genannten Faktoren mittels gezielter Simulationen untersucht werden könnten. Versuche wären bei diesem Vorgehen nach wie vor zur Anpassung der Modellparameter sowie zur Absicherung der Ergebnisse notwendig, allerdings könnten Sie unter Umständen auf ein praktisch durchführbares Maß beschränkt werden. Denkt man noch einen Schritt weiter, so wäre es ebenfalls vorstellbar, dass sich auf Basis gut funktionierender Modelle simulierte Messdaten für das Training neuronaler Netze erzeugen ließen. Ein solch ambitioniertes Ziel erfordert allerdings eine enge und vor allem interdisziplinäre Zusammenarbeit der verschiedensten Fachbereiche, wie Maschinenbau, Elektrotechnik, Signalverarbeitung und Akustik, um nur einige wenige zu nennen.

Literatur

- [1] Kalbfleisch, J.D.: Prentice, R.L.: The statistical analysis of failure time data. Wiley, New York, 1980
- [2] Chesley, J.C.: Handbook of reliability prediction procedures for mechanical equipment. Naval Surface Warfare Center, West Bethesda, 1998
- [3] Fleischer, J.; Weismann, U.; Nesges, D.; Wawerla, M.: Life-Cycle-Performance in der Produktionstechnik. VDI-Z 10 (2004), 87
- [4] Brecher, C.; Klein, W.; Paepenmüller, F.: Ansätze zur Schadensdiagnose an Linearführungssystemen. ZWF 7-8 (2006), 408-411
- [5] Russ AG (Hrsg.): Linearlager und Linearführungssysteme. Expert Verlag, Ehningen bei Böblingen, 1992