



TECHNISCHE
UNIVERSITÄT
WIEN



DIPLOMARBEIT

Machine Learning: Identifikation von Prozessinstabilitäten beim Fräsen

ausgeführt zum Zwecke der Erlangung des akademischen Grades eines

Diplom-Ingenieurs

unter der Leitung von

Univ.-Prof. Dipl.-Ing. Dr.techn. Friedrich BLEICHER

(Institut für Fertigungstechnik und Photonische Technologien)

und unter der Betreuung durch

Dipl.-Ing. Paul SCHÖRGHOFER

Dipl.-Ing. Dr.techn. Norbert LEDER

Dipl.-Ing. Christoph RAMSAUER

eingereicht an der Technischen Universität Wien

Fakultät für Maschinenwesen und Betriebswissenschaften

von

Ralf OSWALD

01426533 (Kennzahl: 066 445)

Krappgasse 5

3712 Maissau

Wien, im Oktober 2019

Ralf Oswald, BSc

Eidesstattliche Erklärung

Ich habe zur Kenntnis genommen, dass ich zur Drucklegung meiner Arbeit unter der Bezeichnung

DIPLOMARBEIT

nur mit Bewilligung der Prüfungskommission berechtigt bin.

Ich erkläre weiters eidesstattlich, dass ich meine Diplomarbeit nach den anerkannten Grundsätzen für wissenschaftliche Abhandlungen selbstständig ausgeführt habe und alle verwendeten Hilfsmittel, insbesondere die zugrunde gelegte Literatur, genannt habe.

Weiters erkläre ich, dass ich dieses Diplomarbeitsthema bisher weder im In- noch Ausland (einer Beurteilerin/einem Beurteiler zur Begutachtung) in irgendeiner Form als Prüfungsarbeit vorgelegt habe und dass diese Arbeit mit der vom Begutachter beurteilten Arbeit übereinstimmt.

Kurzfassung

Diese Arbeit baut auf der Entwicklung des Sensorischen Werkzeughalters auf. Dieser Werkzeughalter ist unter anderem mit einem Beschleunigungssensor ausgestattet und wurde von der Firma myTool IT und dem Institut für Fertigungstechnik und Photonische Technologien entwickelt. Nun ist es entscheidend, wie mit den gemessenen Beschleunigungsdaten verfahren wird, um Aussagen über den Fräsprozess zu treffen und diesen zu optimieren. Das Hauptaugenmerk dieser Arbeit liegt dabei auf dem Unterscheiden von stabilen und instabilen Prozessen mithilfe von selbst erstellten Stabilitätsindikatoren. Dafür wird zuerst die Theorie der Prozessstabilität beim Fräsen mit Hilfe der Stabilitätskarten erläutert, um tiefere Einblicke in die Thematik und ein besseres Verständnis für die Stabilität des Fräsprozesses zu erlangen. In weiterer Folge werden Fräsversuche durchgeführt. Die Versuche werden mit den zuvor erstellten Stabilitätskarten verglichen und in Einklang gebracht. Bei diesen Versuchen wird auch der Luftschall gemessen, welcher es ermöglicht, die Akustik des Prozesses zu späteren Zeitpunkten noch einmal wahrzunehmen. Neben den Schallmessungen wird außerdem mit Bildaufnahmen die Qualität der Oberfläche dokumentiert. Die Akustik und Oberflächen der Fräsversuche werden analysiert und dienen als Hilfe zur Klassifikation der Stabilität. Die einzelnen Stabilitätsklassen sind für die Trainingsdaten der Machine Learning Algorithmen entscheidend. Die Beschleunigungsdaten dienen zum Erstellen von Stabilitätsindikatoren, welche sowohl aus dem Zeitbereich, als auch dem Frequenzbereich gewonnen werden. Durch die Bewertung der ermittelten Indikatoren nach unterschiedlichsten Kriterien, werden nur die signifikantesten unter ihnen für das Machine Learning verwendet. Folgend wird ein neuronales Netz trainiert. Die damit geschaffene künstliche Intelligenz ist in der Lage, anhand des Sensorsignales zu bewerten, ob der aktuell vorliegende Prozess stabil oder instabil ist. Durch einen zuvor durchgeführten Impulshammerversuch ist eine Abschätzung dahingehend möglich, wie weit die Drehzahl, bei Vorliegen eines instabilen Prozesses, erhöht beziehungsweise vermindert werden muss, damit sich der Prozess stabilisiert.

Diese Arbeit dient als Grundstein für weitere Überlegungen zur Prozessoptimierung mit Hilfe des Sensorischen Werkzeughalters. Dies könnte unter anderem die Implementierung eines Systems sein, welches selbst anhand von Beschleunigungsdaten eines Fräsprozesses eigenständig lernt und damit die manuelle Feature Extraction und Feature Selection obsolet wird. Der Sensorische Werkzeughalter könnte hier als Subkomponente in einem kognitiven System gesehen werden, welches aus einer Vielzahl an Sensoren besteht.

Abstract

This work is based on the development of the Sensory Tool Holder, which was developed by the company myTool IT cooperating with the Institute of Production Engineering and Photonic Technologies. This diploma thesis should show how the measured data has to be treated to predict the stability of the milling process with the help of machine learning algorithms.

The main task is to demonstrate the classification of milling processes with self-made stability indicators. The first part, is a comprehensive research about the theory of stability lobe diagrams to get a much deeper insight and better understanding of milling instabilities. The next step is to carry out tests, compare them to the stability lobe diagram and adapt the diagram. The machine learning algorithms require classified training and testing data. Sound measurements and pictures of the workpiece surface are recorded, to support the classification of the data in the right way. From the acceleration signal of the Sensory Tool Holder, stability indicators are created, which have their origin of the time domain and the frequency domain. After the creation of indicators, they get rated and the most significant get picked. With the right indicators and an adequate amount of training data, the neural network can be trained. Based on the Sensory Tool Holder signal, this artificial intelligence is able to classify the process into the classes stable or unstable. How much the spindle speed should be increased or decreased to stabilize the process will be estimated by a tap test of the machine structure. This work is an important foundation for the optimization of the milling process with the Sensory Tool Holder. Subsequently, the machine learning algorithm can be improved in order to skip the manual feature extraction and feature selection to create a self-learning algorithm. The Sensory Tool Holder function as a subsystem of a cognitive system, consisting of multiple sensors, for example temperature or force sensors, to monitor and control the process in the best way.

Inhaltsverzeichnis

Eidesstattliche Erklärung	i
Kurzfassung	iii
Abstract	v
Vorwort und Dank	vii
1 Einleitung	1
1.1 Forschungsfragen und Ziel	2
1.2 Motivation für diese Arbeit	3
1.3 Arbeits- und Herangehensweise	3
1.4 System Sensorischer Werkzeughalter	3
1.4.1 Voruntersuchung - Drehzahlabhängigkeit des Signals	4
1.5 Prozessinstabilitäten beim Fräsen	7
1.6 Potenzialanalyse	7
2 Stabilitätskarten	11
2.1 Allgemein	11
2.2 Stabilitätsalgorithmus von Altintas und Budak	13
2.2.1 Erstellen von Stabilitätskarten für zwei Freiheitsgrade	13
2.2.2 Stabilitätsalgorithmus für einen Freiheitsgrad	19
2.2.3 Superposition verschiedener Eigenformen	20
2.3 Verifikation des Modells	21
2.3.1 Vergleich der Ergebnisse des abgeleiteten Modells mit jenen aus einer Parameterstudie	21
2.3.2 Vergleich mit Software CutPro	23
2.4 Schlussfolgerungen aus dem Stabilitätsalgorithmus	24
2.4.1 Drehzahlbereiche bei maximaler Grenzschnitttiefe	24
2.4.2 Drehzahlbereiche bei minimaler Grenzschnitttiefe	25
2.4.3 Weitere Überlegungen	26
2.5 Erkenntnisse aus den Stabilitätskarten für die Regelung	27
3 Versuche	29
3.1 Versuchsaufbau und Vorversuche	29
3.1.1 Aufbau und verwendete Maschinen	29
3.1.2 Bestimmung der Eigenfrequenzen mittels Impulshammerversuch	31

3.1.3	Abschätzung von Eigenfrequenz und Gesamtsteifigkeit des Systems	31
3.1.4	Erstellung einer Versuchs-Stabilitätskarte	33
3.2	Versuchsdurchführung	33
3.3	Ergebnisse und Auswertung	34
3.3.1	Klassifikation von stabilen und instabilen Prozessen	37
3.3.2	Gegenüberstellung von Signalen im Zeitbereich	38
3.3.3	Gegenüberstellung von Signalen im Frequenzbereich	42
4	Erstellung und Auswahl von Stabilitätsindikatoren	45
4.1	Feature Extraction im Zeitbereich	45
4.1.1	Zentrale Tendenz: Arithmetisches Mittel, Median, Quantilen	46
4.1.2	Streuungsmaße: Varianz, Interquartilsabstand	46
4.1.3	Gestaltmaße: Schiefe, Wölbung	47
4.1.4	Störmaße: Entropie	47
4.2	Feature Extraction im Frequenzbereich	47
4.3	Feature Selection	51
5	Machine Learning	55
5.1	Einführung zu künstlicher Intelligenz	55
5.1.1	Machine Learning	56
5.1.2	Supervised Machine Learning	57
5.1.3	Deep Learning	58
5.2	Anwendung von ML: Herzton-Klassifizierung	59
5.3	Erstellung des neuronalen Netzes	60
5.3.1	Training und Validierung	61
5.4	Analyse der falsch klassifizierten Messreihen	63
5.4.1	Versuch 1040 (false-positive / Fehler 1.Art)	64
5.4.2	Versuch 1170 (false-positive / Fehler 1.Art)	65
5.4.3	Versuch 2060 (true-negative / Fehler 2.Art)	65
5.5	Verwendung des Modells	66
6	Conclusio und Ausblick	67
6.1	Beantwortete Forschungsfragen	67
6.1.1	Gefundene Stabilitätsindikatoren	68
6.1.2	Implementierter Algorithmus	68
6.2	Ausblick	68
6.2.1	Automatisiertes Machine Learning	69
6.2.2	Kognitive Systeme	69
	Literatur	71
	Abbildungsverzeichnis	73

Tabellenverzeichnis	76
Abkürzungsverzeichnis und Physikalische Konstanten	79
A Python Code	83
A.1 Berechnung und Plotten der Stabilitätskarte	83
A.2 Brechnung und Plotten des Übertragungsfrequenzgangs	89
A.3 Selbsterstellte Funktionen	91
A.4 Datenauswertung: Zeitreihenplots und Spektrumplots	97
A.5 Feature Extraction	100
A.6 Feature Selection	102
A.7 Erstellen des Neuronalen Netzwerks	105
A.8 Nutzen des Neuronalen Netzwerks	107
B Versuchsprotokoll	109
C Fräserdatenblatt	115