

FERTIGUNGSPARAMETERSCHÄTZUNG ZUR VORGESCHRIEBENEN OBERFLÄCHENQUALITÄT MITTELS NEURONALEN NETZES

Osanna, P. H. & Monostori, L. & Alpek, F. & Viharos, Zs. J.

Schlüsselworte: *Bearbeitungsparameterschätzung, Vorschub, Schnitttiefe, Schnittgeschwindigkeit, Plandrehen, Stirnfräsen, Neuronales Netz, Modifiziertes Art2 Netz, Traditionelle Kenngrößen*

1 PROBLEMBESCHREIBUNG

In der Maschinenbau taucht oft die Forderung auf, um Maschinen zu entwickeln, die mit den verschiedenen veränderlichen Fertigungsumständen selbst umgehen können. Es gibt schon Fertigungsstraßen, die fast keine menschliche Überwachung brauchen, aber hier sind die einzelnen Wechselzeiten vorgeschrieben, aber bei nicht erwarteten Effekten arbeitet die Maschine nicht optimal und werden die Fertigungskosten zu groß. Das Ziel ist, Maschinen zu entwickeln, die schon während der einzelnen Fertigungsphasen die Qualität des Endproduktes schätzen, und damit schon während einer Fertigungsphase gut eingreifen können. Dieses Ziel realisieren zu können, braucht man die Zusammenhänge zwischen den einzelnen Qualitätsmerkmalen und den einzelnen physikalischen Parametern der Fertigung. Im Laufe unserer Forschungstätigkeit versuchten wir ein „neuronales Netz“ Modell aufzustellen, welches diese Zusammenhänge lernen kann, und wir möchten auch neue Informationen mit Hilfe des Netzes bekommen.

2 AUFGABESTELLUNG

Wir versuchten die Zusammenhänge zwischen 3 Fertigungsparametern und der Rauheit der hergestellten Oberflächen mit einem von uns modifiziertes ART2 neuronales Netz zu lernen. Die 3 Fertigungsparametern waren :

- der Vorschub,
- die Schnittgeschwindigkeit,
- die Schnitttiefe.

In unserer früheren Arbeit versuchten wir Oberflächen, die mit 4 Bearbeitungsverfahren hergestellt wurden, anhand derer Rauheit voneinander mit dem gleichen Netz trennen. Da wir die besten Ergebnissen mit den traditionellen Kenngrößen bekommen hatten, verwendeten wir bei der Parameterschätzung diese. Insgesamt verwendeten wir zehn Rauheitskenngrößen. Also unser Ziel war anhand dieser zehn Rauheitskenngrößen die einzelnen Fertigungsparametern schätzen zu können. Auch Information können wir nur Anhand dieser zehn Rauheitskenngrößen bekommen.

3 FORSCHUNGSMETHODEN

3.1 Die Umstände der Fertigung

Um das neuronales Netz lehren zu können, braucht man als Musterbeispiele Mustervektoren. Wir haben dazu mit zwei Verfahren,

- mit Stirnfräsen 20,
- mit Plandrehen 50

Oberflächen fertigen lassen. Wir variierten die 3 Fertigungsparametern und hielten die anderen physikalischen Umstände möglichst konstant. Beim Stirnfräsen gehört zu eine Oberfläche eine Kombination der 3 Fertigungsparametern, aber beim Plandrehen ändert sich die Schnittgeschwindigkeit entlang der Radius. So gehört zu einer plangedrehten Oberfläche eine Kombination von 2 Parametern. Wir nahmen an, daß die Schnittgeschwindigkeit entlang der Meßlänge konstant ist. Ein Oberflächemusterstück gehört zu dem gleichen Fertigungsumstand. Die Zahl der Oberflächemusterstücke waren beim Stirnfräsen 20, beim Plandrehen 150.

3.2 Die Umstände der Messungen, die angewandte Kenngrößen

Nach der Fertigung haben wir die Oberflächen mit Tastschnittverfahren gemessen und die Mittelwerte deren Kenngrößen, die zu der gleichen Fertigungsumständen gehören, ausgerechnet. Der Radius der Diamantspitze des Meßgeräts war 5 µm. Die Kenngrößen waren :

1. R_{max} : Maximale Rauhtiefe ($\max(R_{zi})$)
2. R_z : Gemittelte Rauhtiefe : aufgrund 5 Teilmeßstrecken
3. R_p : Maximale Profilspitzenhöhe
4. R_{pm} : Gemittelte Glättungstiefe
5. R_{3z} : Grundrauhtiefe
6. R_a : Mittenrauhwert
7. R_q : Quadratischer Mittenrauhwert
8. R_t : Maximale Rauhtiefe (absolut)
9. P_t : Profiltiefe
10. R_{sm} : Mittlerer Rillenabstand

3.3 Die Klassifikationsvariationen

Für die Klassifikation bildeten wir zwei Mustervektorsorten :

1. Ein Mustervektor, der aus den einzelnen Mittelwerte der verschiedenen Kenngrößen steht.
2. Ein Mustervektor, welcher bis die 10. Komponent gleich ist als der vorige, aber die 11. Komponent ist die Länge des Vektors.


Unter der zwei Mustervektorsorten machten wir noch zwei Transformation :

1. Zuerst wendeten wir die zwei o.g. Mustervektorsorten zu der Klassifikation an.
2. Zu der zweiten Klassifikation transformierten wir die Mustervektorsorten so, daß die einzelnen Komponenten der gesamten Mustervektoren zwischen 0 und 1 lagen.

So bekamen wir insgesamt $2 \times 2 = 4$ Mustervektortypen. Die einzelnen Fertigungsparametern ordneten wir anhand ihrer Größe in 3 Gruppen. Wir hatten Mustervektoren von 2 Fertigungsverfahren, von 4 Mustervektortypen und wir hatten 3 Fertigungsparametern zu Schätzen. Insgesamt machten wir $2 \times 4 \times 3 = 24$ Klassifikationen.

3.4 Die Klassifikation des von uns modifizierten ART2 Netzes

Das ART2 ist ein unbewachtes Netz.



Um einige Schritte in Richtung überwachtes Netz zu realisieren, führten wir neben den 2 Schichten

eine 3. Schicht ein. Nennen wir die Klassen welche das ursprüngliche Netz zustande bringt nicht Klassen, sondern Clustern. Klasse wird dann gesagt wenn man an die Klassen denkt, welche von uns erwünscht sind. Die Clustern kann man bei der F2 Schicht finden, aber die Klassen kommen bei der F3 Schicht vor. Wir änderten den Aufmerksamkeitsparameter ρ solange, bis die Klassifizierung ohne oder mit sehr geringem Fehler läuft. Fehler wird dann gesagt, wenn das Netz solche zwei Vektoren in demselben Cluster einordnet, welche aber in verschiedenen Klassen kommen sollten. „Richtig“ bedeutet wieviel solche Vektoren in eine Cluster eingeordnet werden, welche in gleiche Klasse gehören sollen. Um Informationen zu bekommen, untersuchten wir die Zusammenhänge zwischen Fehler und „Richtig“. Wir machten die Klassifikation beim 50, 40, 30, 20, 10, 5 % Fehlerprozent und wir zählten wieviel „richtige“ Mustervektoren aufgetaucht sind. Das Netz arbeitet so, daß unter der Klassifizierung einige Mustervektoren als Lehrvektoren und einige als Testvektoren dienen.

3.5 Ergebnissen

Die Ergebnisse der Bearbeitungsparameterschätzung sollen wir aus zwei Gesichtspunkten sehen. Die Ergebnisse hängen von der Zahl der Lehrstücke und auch von dem erlaubten Fehler ab. Beim Stirnfräsen wurde nur wenig Mustervektoren als „richtig“ erkannt. Mit den Umfang von 70-80% der Musterstücke als Lehrstücke konnten wir die technologischen Daten mit 30-40% Fehler sätzen. Es ist wahrscheinlich deshalb so, weil die Zahl der Oberflächemusterstücke wenig war. Beim Plandrehen war die Zahl der Oberflächemusterstücke genügend. Hier konnten wir die verschiedenen technologischen Daten mit verschiedenen Ergebnissen schätzen. Die besten Ergebnisse tauchten beim Vorschub beim 10% Fehler auf. Hier konnten wir den Vorschub nur mit 26% der Mustervektoren als Lehrvektoren und 74% als Testvektoren gut schätzen. Da die Ergebnisse bei der 1. Mustervektorsorte besser waren als bei der 2., kann man sehen, daß die zueinander relative Lage der einzelnen Mustervektoren eine wichtige Rolle spielt und der absolute Wert der Rauheitskenngrößen nicht so große Bedeutung hat. Bei der Schätzung der Schnitttiefe beim 20% Fehler brauchten wir 78% der Meßdaten als Lehrdaten und konnten wir nur 22% der Mustervektoren als Testdaten verwenden. Bei der Schätzung der Schnittgeschwindigkeit beim 20% Fehler brauchten wir 80% der Meßdaten als Lehrdaten und konnten wir nur 20% als Testdaten verwenden. So kann man sehen, daß wesentliche Ergebnisse nur beim Plandrehen beim Vorschub aufgetaucht sind. Wahrscheinlich braucht man bei der Schätzung der anderen Parametern andere Kenngrößen oder andere Rauheitsmerkmalen.

4 WEITERE FORSCHUNGSRICHTUNGEN

Die Entwicklungsrichtungen sollen wir von zwei Standpunkt sehen :

1. Vom Standpunkt der Fertigungs und Meßtechnik :
 - Man soll nicht nur die Rauheit sondern noch mehrere Eigenschaften messen: zB.

Materialeigenschaften, Werkzeugdaten, Schwingungen, usw.

- Die Oberflächequalität soll nicht nur anhand einer zwei dimensionalens Messung (Tastschnittverfahren) bewertet sein, sondern soll man die drei dimensionale Oberfläche in acht nehmen. Auch bei der zwei dimensionalens Messung soll man viel mehrere Rauheitskenngrößen entwickeln.

- Die Genauigkeit der Messungen soll noch erhöht werden. In dieser Richtung können wir schon heute sehr schöne Ergebnisse sehen. Die Problemen dieser Messungen sind am meisten die Meßumstände. Diese Meßgeräte sind noch im alltäglichen Fertigungstechnik kaum verwendbar.

2. Vom Standpunkt des neuronalen Netzes :

- Es wäre gut, wenn das Netz die Eigenschaften eines beaufsichtigten Netzes hätte. Zuerst haben wir die dritte Schicht eingeleitet. Wir sollen noch statt graphische Auswertung der Ergebnissen exakte numerische Auswertung entwickeln. Es wäre gut wenn wir die guten Eigenschaften eines aufbewachten und eines unbeaufsichtigten Netz in einem neuen Netz integrieren könnten. Diese Entwicklung kann man wahrscheinlich mit Hilfe eines krummlinieigen Koordinatensystems realisieren.

- Es ist sehr wichtig, daß bei den einzelnen Parametern beim Zusammenhang zwischen fehlerhaft und „richtig“ oft ein Maximum vorkommt. Es zeigt, daß die optimale Klassifikation, also der optimale Wert von ρ beim diesem Fehlerprozent liegt. Mit Hilfe dieses Effektes können wir wahrscheinlich auf die Parameterschätzungsfähigkeit des Netzes folgern.

Zur Zeit versuchen wir in diese Richtungen weiterzugehen.

5 LITERATURANGABEN

- [1] Alpek, F.; Viharos, Zs. J., Erfahrungen am Einsatz von neuronalen Netzen zur Bewertung der Oberflächenqualität, 6. DAAAM, 011-012, Krakkau, Oktober 1995
- [2] Jürgen Kraus, „Entwurf und Realisierung eines neuronalen Netzwerkes nach der „Adaptive Resonance Theory“ in C“, Universität Gesamthochschule Paderborn, 1991.
- [3] Monostori, L.; Kadar, B.; Egesits, C., Virtual Manufacturing by Coupling Connectionist and Expert Systems, 6. DAAAM, 231-232, Krakkau, Oktober 1995
- [4] Gail A. Carpenter, Stephen Grossberg, A Massively Parallel Architecture for a Self-Organizing Neural Pattern Recognition Machine, Computer Vision, Graphics, and Image Processing, 54-115, Januar 1987.

AUTHOREN

a.o. Univ.-Prof. Dr. P. H. **OSANNA**, Leiter der Abteilung Austauschbau und Meßtechnik, TU Wien, Karlsplatz 13, A-1040 Wien, Austria, Tel : 43-1-58801-3189

Prof. László **MONOSTORI**, Computer and Automation Research Institute, Hungarian Academy of Sciences, Kende u. 13-17, H-1518 Budapest, Hungary
E-mail: laszlo.monostori@sztaki.hu

Dr.-Ing. Univ. Doz. Ferenc **ALPEK**, Lehrstuhl Fertigungstechnik, TU Budapest, H-1111 Budapest, Műegyetem rkp. 3, Hungary, Tel : 36(1)4632518

E-mail: alpek@next-1b.manuf.bme.hu

Dipl. Ing. Zsolt János **VIHAROS**, PhD Student, Lehrstuhl Fertigungstechnik, TU Budapest, H-1111 Budapest, Műegyetem rkp. 3, Hungary

E-mail: vihi@next-1b.manuf.bme.hu