

Busse, Anja M.; Hüsken, Michael; Stagge, Peter

Working Paper

Offline-Analyse eines BTA-Tiefbohrprozesses

Technical Report, No. 2001,16

Provided in Cooperation with:

Collaborative Research Center 'Reduction of Complexity in Multivariate Data Structures' (SFB 475), University of Dortmund

Suggested Citation: Busse, Anja M.; Hüsken, Michael; Stagge, Peter (2001) : Offline-Analyse eines BTA-Tiefbohrprozesses, Technical Report, No. 2001,16, Universität Dortmund, Sonderforschungsbereich 475 - Komplexitätsreduktion in Multivariaten Datenstrukturen, Dortmund

This Version is available at:

<https://hdl.handle.net/10419/77101>

Standard-Nutzungsbedingungen:

Die Dokumente auf EconStor dürfen zu eigenen wissenschaftlichen Zwecken und zum Privatgebrauch gespeichert und kopiert werden.

Sie dürfen die Dokumente nicht für öffentliche oder kommerzielle Zwecke vervielfältigen, öffentlich ausstellen, öffentlich zugänglich machen, vertreiben oder anderweitig nutzen.

Sofern die Verfasser die Dokumente unter Open-Content-Lizenzen (insbesondere CC-Lizenzen) zur Verfügung gestellt haben sollten, gelten abweichend von diesen Nutzungsbedingungen die in der dort genannten Lizenz gewährten Nutzungsrechte.

Terms of use:

Documents in EconStor may be saved and copied for your personal and scholarly purposes.

You are not to copy documents for public or commercial purposes, to exhibit the documents publicly, to make them publicly available on the internet, or to distribute or otherwise use the documents in public.

If the documents have been made available under an Open Content Licence (especially Creative Commons Licences), you may exercise further usage rights as specified in the indicated licence.

Offline-Analyse eines BTA-Tiefbohrprozesses

Anja M. Busse^{1,2}, Michael Hüsken¹, Peter Stagge¹

¹Institut für Neuroinformatik, Ruhr-Universität Bochum, 44780 Bochum, Deutschland

²LS für Computergestützte Statistik, Universität Dortmund, 44221 Dortmund, Deutschland

E-Mail: {Anja.Busse,Michael.Huesken}@neuroinformatik.ruhr-uni-bochum.de,
Peter.Stagge@thinking-networks.com

Zusammenfassung

Methoden der mathematischen und statistischen Zeitreihenanalyse stellen Werkzeuge zur Charakterisierung von Prozessen zur Verfügung. In dieser Veröffentlichung werden Messdaten untersucht, die bei einem BTA-Tiefbohrprozess erhoben wurden. Die Charakterisierung dieses Prozesses ist von besonderer Relevanz, da vereinzelt unerwünschte Zustände, wie z. B. Rattern, auftreten können. Aufbauend auf der Analyse des Prozesses ist die Organisation eines Eingriffs zwecks Unterdrückung dieser Zustände denkbar und angestrebt.

Die vorliegende Analyse zeigt, dass der Bohrprozess stark durch die Eigenfrequenzen der Bohrstange geprägt ist. Zusätzlich wird heraus gestellt, dass Übergänge zu unerwünschten Zuständen des Bohrprozesses durch unterschiedliche Methoden, wie z. B. der Berechnung der Autokorrelationsfunktionen, identifiziert werden können. Es zeigt sich, dass eine lineare Prozessmodellierung gute Ergebnisse erzielt, wobei allerdings neuronale Netze, also nichtlineare Modelle, eine leichte Verbesserung bewirken. Diese Tatsache deutet an, dass der Prozess neben den dominanten linearen Anteilen auch geringfügige nichtlineare Komponenten aufweist.

1 Einleitung

Um lange Metallbohrungen mit hoher Oberflächengüte herstellen zu können, wurde im Maschinenbau das so genannte *BTA-Tiefbohren* entwickelt (VDI-Richtlinie 3210, 1974). Die hierzu verwendeten Werkzeuge sind sehr schlank, so dass es aufgrund geringer Steifigkeit zu *Rattern* führt. Dieser Zustand verursacht Oberflächenfehler am Werkstück, den so genannten Rattermarken. Diese Rattermarken führen zu hohem Qualitätsverlust am Werkstück. Neben den Riefen im Werkstück geht Rattern mit einer starken Lärmbelästigung einher. Als weitere Ratterfolgen sind ein hoher Verschleiß an Schneiden und Führungsleisten, die sich in der Tiefbohrmaschine befinden, zu nennen. Auch eine Gefährdung des Werkstücks

bis hin zum Werkzeugbruch ist nicht selten eine Folge von Rattern. Zum an deren wird die Ausnutzung der Antriebsleistung der Tiefbohrmaschine durch ein ansteigendes Bohrmoment reduziert (Weinert, Webber, Busse, Hüsken, Mehnen und Stagge, 2001). Um diesen unerwünschten Zustand vermeiden zu können, sind Kenntnisse über den Bohrprozess und über die Ursachen des Ratterns notwendig.

Ziele dieser Arbeit sind, für den untersuchten Tiefbohrprozess zu einem tieferen Prozessverständnis zu kommen und erste Modellierungsversuche vorzunehmen. Hierzu werden in Kapitel 2 zunächst die gemessenen Daten vorgestellt und mit Hilfe einer deskriptiven Analyse ein erster Eindruck über den Tiefbohrprozess vermittelt. Hieraus werden sich drei verschiedene Bereiche, ein nichtratternder Zustand, ein Zustand des ersten Ratterns und einer des zweiten Ratterns, kristallisieren, die jeweils mit Hilfe einer Fourieranalyse ausgewertet werden (Kapitel 3.1). Da Wissen über die Entstehung von Rattern ebenfalls zu einem tieferen Prozessverständnis führt, wird der Übergangsbereich vom nichtratternden in den ratternden Zustand durch eine Fourieranalyse, eine Analyse der Autokorrelationsfunktion und der Berechnung der Verteilungsdichten jeweils in gleitenden Zeitfenstern untersucht (Kapitel 3.2). Kapitel 4 wird dann die Prozessmodellierung behandeln, die zum einen mit linearen, zum anderen mit nichtlinearen Ansätzen durchgeführt wird. Eine abschließende Diskussion wird in Kapitel 5 geführt.

2 Datenbeschreibung

Die in dieser Arbeit untersuchten Daten sind bei einem BTA-Tiefbohrprozess von einem im Bohrkopf integrierten Beschleunigungssensor aufgenommen worden. Kapitel 2.1 beschreibt die Datenerfassung und die in diesem Prozess auftretenden Einstellgrößen. Eine deskriptive Analyse der Zeitreihe wird in Kapitel 2.2 gegeben.

2.1 Datenerfassung und Einstellgrößen

Für eine Analyse des Tiefbohrprozesses und die damit verbundene Beschreibung und Modellierung von ratterfreiem und ratterndem Zustand wurde ein *Beschleunigungssensor* am Bohrkopf angebracht (Webber, 1999). Hierdurch ist es möglich, *Torsionsschwingungen* in Form von Zeitreihen auszuwerten. Die Messdaten werden mit einer Abtastfrequenz von $\nu = 15$ kHz aufgenommen. Die vorliegende Zeitreihe des Beschleunigungssensors besteht aus 4050000 Einträgen, was bei der gegebenen Abtastrate 4.5 min entspricht. Einen Eindruck der gesamten Zeitreihe gibt Abbildung 1.

Zu den Einstellgrößen im untersuchten Bohrprozess gehören die *Schnittgeschwindigkeit* v_c und der *Vorschub* f . Die Schnittgeschwindigkeit, also die Geschwindigkeit, mit welcher sich der Rand des Bohrkopfs wegen der Rotation relativ zum Werkstück bewegt, beträgt bei einem Bohrkopfradius von $r = 30$ mm bei dem untersuchten Prozess $v_c = 100$ m/min.

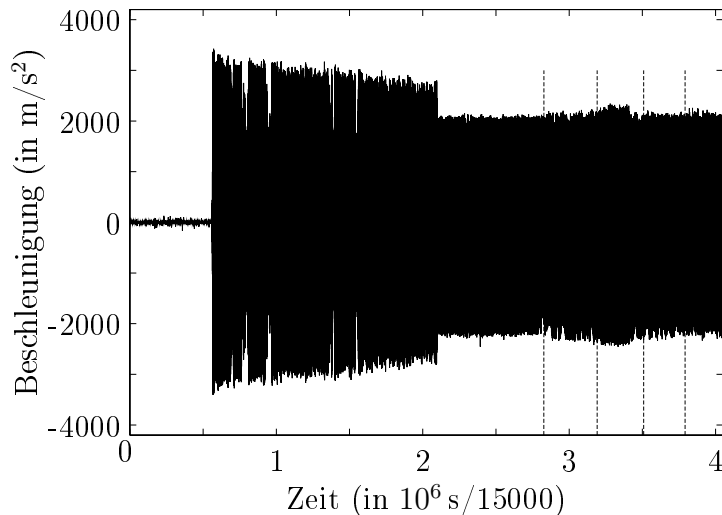


Abbildung 1: Beschleunigung des Bohrkopfs. Die senkrechten Linien markieren die Zeitpunkte, zu denen der Vorschub f um 0.02 mm erhöht wurde.

Eine zum intuitiven Verständnis gebrauchte Größe ist die Anzahl an Messpunkten pro Umdrehung, die somit etwa 1700 Messdaten beträgt.

Der Vorschub, d.h. die axiale Bewegung des Bohrers pro Umdrehung, liegt initial bei $f = 0.12$ mm. Ab einer Bohrtiefe von 200 mm wird f alle 30 mm Bohrtiefe um 0.02 mm bis zu einem Vorschub von $f = 0.20$ mm erhöht. Die Zeitpunkte, zu denen f erhöht wird, sind in Abbildung 1 durch senkrechte Striche markiert.

2.2 Deskriptive Analyse

Bei einer reinen Betrachtung der Zeitreihe lassen sich einige Charakteristiken ausmachen. Zuerst lassen sich drei Abschnitte mit stark unterschiedlicher Amplitude identifizieren. Die Amplitude des Beschleunigungssensors ist in der ersten Phase um etwa zwei Größenordnungen geringer als in einer zweiten Phase. Eine dritte Phase geht im Gegensatz zur zweiten Phase mit einem leichten Abfall der Amplitudenstärke einher. Mit Hilfe der unterschiedlichen Größenordnungen der Amplituden wird eine Unterteilung des Prozesses in drei Zustände vorgenommen, einen ratterfreien Zustand, ein erstes und ein zweites Rattern. Die Grenzen der einzelnen Abschnitte sind nicht mit dem Umstellen des Vorschubs f in Verbindung zu bringen. Vielmehr finden die Umstellungen alle in der Phase des zweiten Ratterns statt und bringen nur eine geringfügige Modifikation des Verhaltens der Bohrkopfbeschleunigung mit sich.

Der Mittelwert der Beschleunigungszeitreihe liegt in den Abschnitten nahe bei 0. Das passt zu der Tatsache, dass mit der Beschleunigung ein differentieller Wert aufgetragen wird. In der ersten Phase des Bohrprozesses erscheint die Zeitreihe des Beschleunigungssensors als stark verrauscht mit einem sehr geringen periodischen Anteil, wohingegen die beiden




Abbildung 2: Beschleunigung des Bohrkopfs im ratterfreien (links) und ratternden (rechts) Zustand.

Phasen des Ratterns ein stark periodisches Verhalten aufweisen. Wird der Übergang vom Nichtrattern zum Rattern genauer betrachtet, so wirkt dieser „wohlgeordnet“ und bezüglich der Amplitudenzunahme „trichterförmig“ (vgl. Abbildung 2).

Da etwa 1700 Messdaten eine Bohrkopfumdrehung entsprechen, setzt Rattern innerhalb von drei Bohrkopfumdrehungen ein. Während des Ratterns herrscht eine einzige Frequenz der Beschleunigung eindeutig vor, während im ratterfreien Fall keine dominante Schwingung sichtbar ist.

3 Datenanalyse

Die deskriptive Analyse des Bohrprozesses identifizierte drei unterschiedliche Phasen. Als weiterführende Analyse werden in diesen Bereichen separat Fourieranalysen durchgeführt (Kapitel 3.1). Da jedoch ein weiteres Ziel dieser Arbeit die frühzeitige Identifikation von Rattern ist, wird der Übergang vom nichtratternden zum ratternden Zustand genauer betrachtet. Die zur Identifikation notwendigen Hilfsmittel bestehen aus der Berechnung von Spektren, von Autokorrelationsfunktionen und von Dichten, jeweils über gleitende Zeitfenster im Übergangsbereich (Kapitel 3.2).

3.1 Fourieranalyse in den charakteristischen Bereichen

Die Fourieranalyse beruht auf einer Zerlegung eines Zeitsignals in Schwingungsamplituden und Phasen. Zu der Zeitreihe des Beschleunigungssensors ergeben Leistungsspektren der verschiedenen charakteristischen Bohrabschnitte einige bemerkenswerte Erkenntnisse.

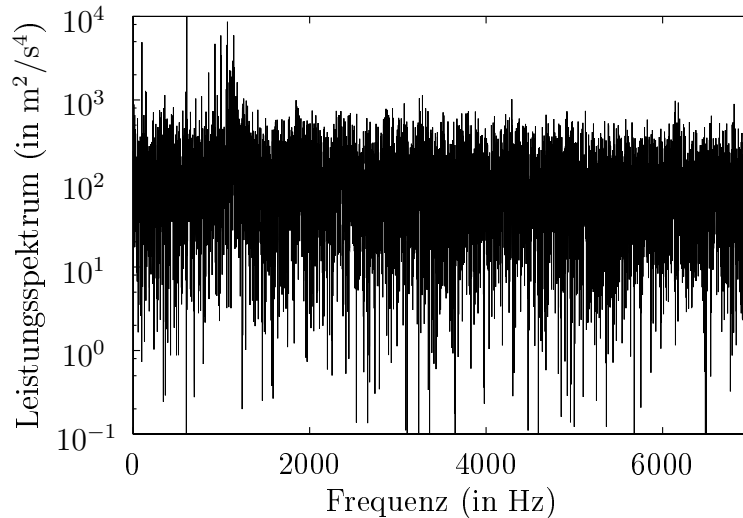


Abbildung 3: Fourier-Spektrum über den Beschleunigungssensor über 16384 Daten aus dem ratterfreien Bereich (Datenpunkte 100001-116384).

Abbildung 3 stellt das Leistungsdichtespektrum in der ratterfreien Phase dar. Schwach erkennbar ergibt sich eine charakteristische Frequenz, die bei etwa 1.2 kHz liegt. Aus Voruntersuchungen (Webber, 1999) ist bekannt, dass diese Frequenz eine der ersten sieben Torsionseigenfrequenzen der Bohrstange ist. Eine niederfrequenter Grundschwingung ist im ratterfreien Bereich nicht zu entdecken.

In dieser Zeitreihe gibt es zwei unterschiedliche Bereiche des Ratterns, für beide Bereiche sind die Leistungsspektren in Abbildung 4 gezeigt. Die linke Abbildung zeigt hochfrequentes Rattern und bezieht sich auf den zweiten charakteristischen Bereich der Messreihe. Das Spektrum des dritten Bereichs ist rechts dargestellt und zeigt niederfrequenteres Rattern. Die Grundfrequenz der linken Abbildung spiegelt deutlich die Torsionseigenfrequenz (1.26 kHz) der Bohrstange wider, wie sie ebenfalls in Abbildung 3 sichtbar ist. Zusätzlich sind Oberschwingungen deutlich erkennbar. Mit dem Anstieg der Frequenzen fällt die Stärke der Oberschwingungen ab.

Die Grundfrequenz der rechten Abbildung ist niedriger. Es handelt sich hier um eine weitere Eigenfrequenz der Bohrstange, die bei etwa 0.24 kHz liegt. Zusätzlich sind weitere Oberschwingungen erkennbar. Diese klingen jedoch auffällig wenig ab. Die Torsionseigenfrequenz der Bohrstange bei 1.26 kHz ist im Gegensatz zum ratterfreien Bereich und vom ersten Rattern in dem Spektrum des zweiten Ratterns weniger deutlich erkennbar. Vermutlich wird diese durch die Oberschwingungen „gedämpft“.

Aus der Frequenzanalyse des Bohrprozesses lässt sich der Schluss ziehen, dass die hier aufgetretenen charakteristischen Frequenzen die unterschiedlichen Phasen, d. h. Nichtrattern, hochfrequentes Rattern und niederfrequentes Rattern, kennzeichnen. Diese charakteristischen Frequenzen entsprechen den Eigenfrequenzen der Bohrstange.




Abbildung 4: Frequenzspektrum der Beschleunigung beim hochfrequente Rattern (links, Datenpunkte 700001-716384) und beim niederfrequenten Rattern (rechts, Datenpunkte 2500001-2516384).

3.2 Untersuchungen im Übergangsbereich

Da anhand der Fourieranalyse eine Unterscheidung der charakteristischen Phasen des Bohrprozesses möglich ist, schließt sich die Frage an, wie der Übergangsbereich vom Nichtrattern zum Rattern (vgl. Abbildung 2) frühzeitig erkannt werden kann. Hier benutzen wir eine Fourieranalyse in gleitenden Fenster (Kapitel 3.2.1). Dem anschließen wird sich eine ebenfalls in gleitenden Fenstern betrachtete Analyse mit der *Autokorrelationsfunktion*, die die Korrelation zu zwei Zeitpunkten zugehörigen Zufallsvariablen eines stochastischen Prozesses wiedergibt (Kapitel 3.2.2). Dichteschätzungen in den gleitenden Zeitfenstern aus dem Übergangsbereich werden die Analyse zur Beschreibung des Wechsels vom Nichtrattern zum Rattern abrunden (Kapitel 3.2.3).

3.2.1 Fouriertransformationen in Fenstern

Um die zeitliche Veränderungen der Fundamentalfrequenzen im Übergangsbereich vom Nichtrattern zum Rattern bestimmen zu können, werden Spektren zu gegebenen Zeitfenstern im Übergangsbereich gebildet. Mit diesem Vorgehen werden zusätzliche Informationen geliefert, wie z.B. die Analyse der Frequenz, die hauptsächlich für das Erregen der Zeitreihe zum Rattern verantwortlich ist.

Es werden Spektren über jeweils 1024 Messpunkte ausgehend von Messpunkt 550096 berechnet (siehe Abbildung 5). Deutlich sind die Veränderungen der Spektren im Übergang zum Rattern zu erkennen. In der noch ratterfreien Phase ist kaum eine charakteristische Frequenz zu erkennen, ähnlich zu Abbildung 3. Nach einiger Zeit wird das Aufschwingen einer Frequenz deutlicher, die sich zum Ende, also im ratternden Zustand, wesentlich heraushebt. Offenbar stellt sich Resonanz zwischen Bohrer und Anregung ein. In den letzten Bildern zeigt sich das Erscheinungsbild des ersten Ratterns, das auch schon in Kapitel 3.1 zu sehen war. Diese Fundamentalfrequenz ist die typische Torsionseigenfrequenz, die bei

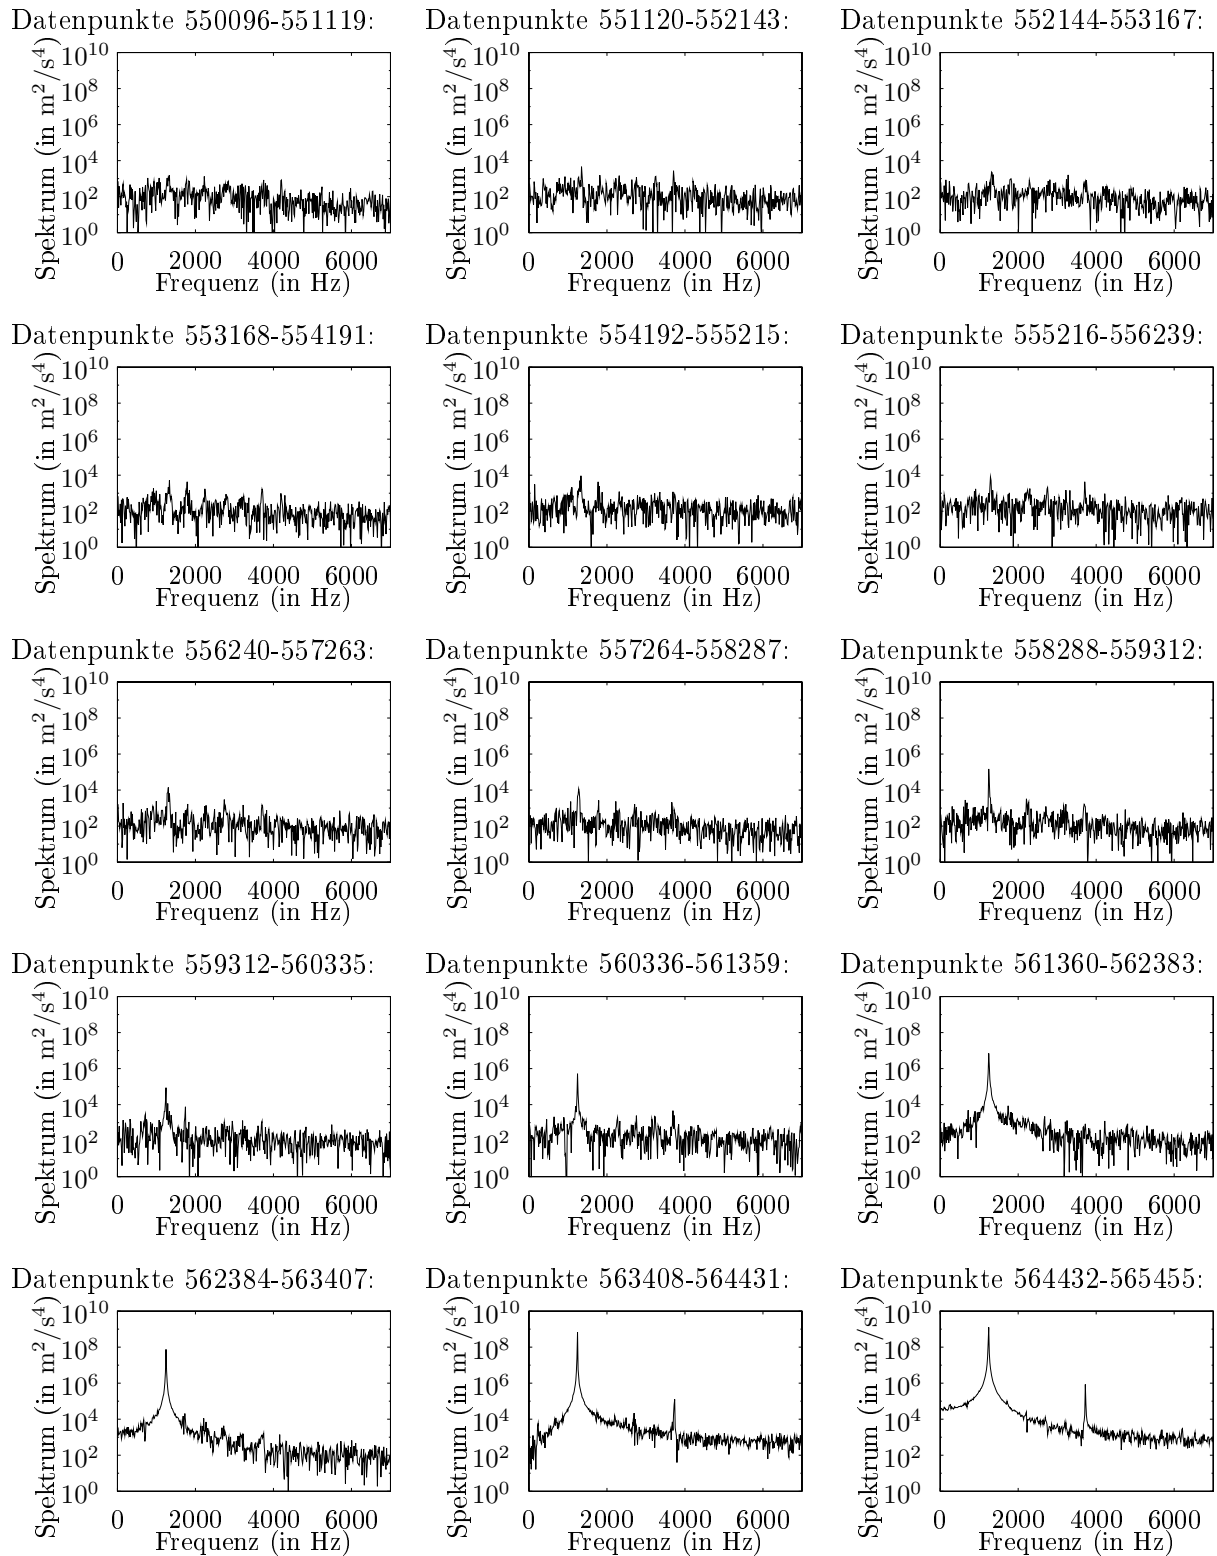


Abbildung 5: Spektren über je 1024 Datenpunkten im Bereich des Übergangs zum Ratten.

etwa 1.2 kHz liegt. Es ist somit möglich, die Spektren zur Charakterisierung des Übergangs zum Rattern heran zu ziehen.

3.2.2 Autokorrelationsfunktionen über ein Fenster

Um weitere Einsichten über die Modellierung des zugrunde liegenden Prozesses zu gewinnen, werden die empirischen Autokorrelationsfunktionen, kurz ACF, im Zeitfenster herangezogen. Hierbei beschreibt die ACF die Korrelation zwischen je zwei Zeitpunkten eines stochastischen Prozesses, jeweils in Abhängigkeit von unterschiedlichen zeitlichen Abständen (Kendall und Ord, 1990; Brockwell und Davis, 1996).

Um den Übergangsbereich möglicherweise mit Hilfe der ACF beschreiben zu können, werden die verschiedenen ACFs wie bei der Fourieranalyse im Zeitfenster wieder über jeweils 1024 Messpunkte ausgehend von Messpunkt 550096 berechnet (siehe Abbildung 6). Sowohl im ratterfreien als auch im ratternden Zustand klingen die ACF nicht ab. Eine Veränderung in der Abfolge der verschiedenen Autokorrelationsfunktionen ist schon sehr schnell zu erkennen. Klare Schwingungen werden deutlich sichtbar. Im Gegensatz zu den vorher untersuchten Spektren (vgl. Kapitel 3.2.1) ist das Rattern anhand der ACF früher erkennbar.

Von der Form der ACF lässt sich auf mögliche Modellklassen bei der Modellierung zurück-schließen (Brockwell und Davis, 1996). Für eine Modellierung des Übergangsbereichs bzw. des Ratterns sollte aufgrund dieser Analyse ein Schwingungsmodell den Vorzug finden. Jedoch ist ebenfalls festzuhalten, dass eine Modellierung der Daten im ratterfreien Zustand mit Hilfe von ARMA-Modellen denkbar ist.

3.2.3 Dichtefunktionen über ein Fenster

Wird der zeitliche Aspekt vernachlässigt, ist eine weitere Untersuchungsmethode des Übergangs vom ratterfreien zum ratternden Zustand in dem untersuchten Bohrprozess die Dichteschätzung. Wieder wird der Übergang ins Rattern in der Zeitreihe des Beschleunigungs-sensors betrachtet, wie in Abbildung 2 gezeigt. Die durch Kerndichteschätzung ermittelten Dichten wurden aus jeweils 1024 Messpunkten gebildet, ausgehend von Messpunkt 550096 (siehe Abbildung 7). Es sei noch darauf hingewiesen, dass die Achsenskalierung aus Betrachtungsgründen unterschiedlich gewählt ist.

Es zeigt sich im Übergang vom Nichtrattern zum Rattern, dass sich die Verteilungen von eingipfligen, symmetrischen Funktionen zu zweigipfligen Dichten verändern. Eine mögliche Ursache ist, dass die Zweigipfligkeit durch eine sinusartige Schwingung zustande kommt. Die Eingipfligkeit ist ein Hinweis darauf, dass eine spätere Modellierung mit linearen Modellen im ratterfreien Zustand möglich sein kann. Eine Art „Bauchigkeit“ zwischen den Modi ist in den letzten Bildern der Abbildung 7 zu erkennen. Eine Symmetrie bleibt in allen Bildern erhalten.

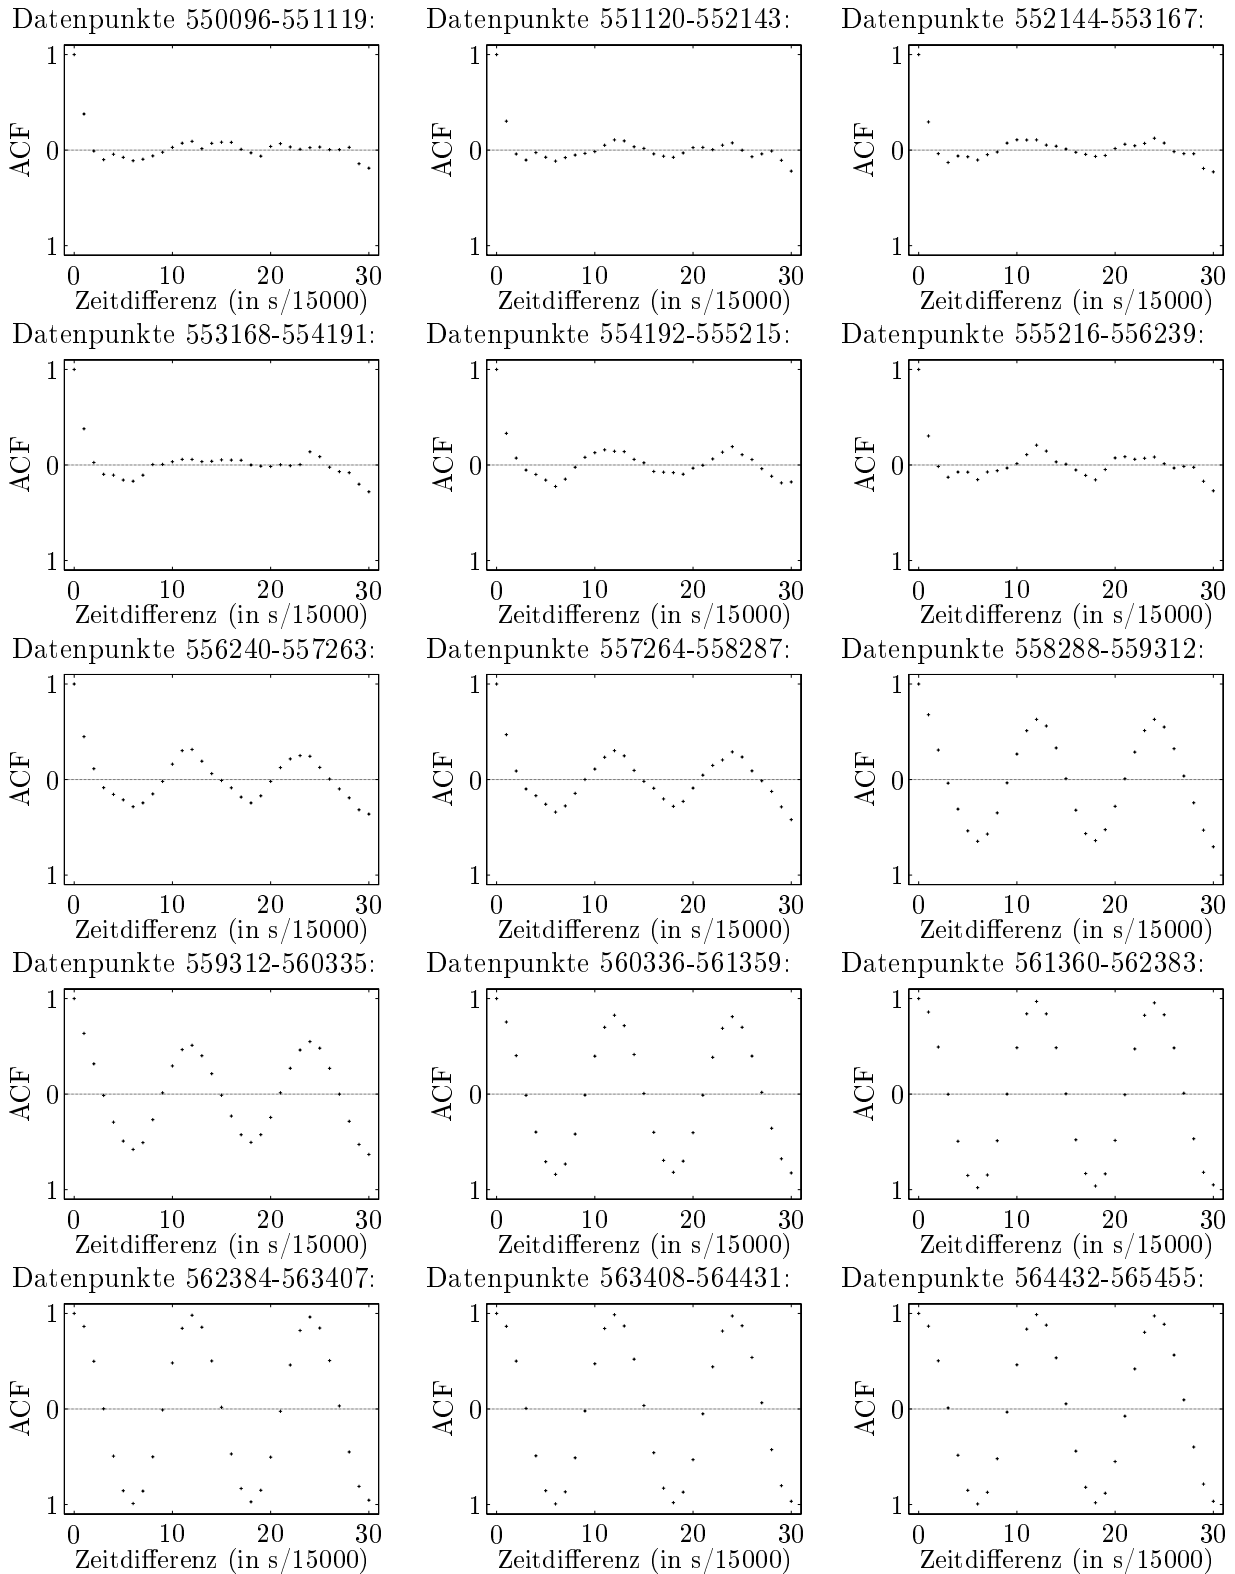




Abbildung 6: Autokorrelationsfunktionen über je 1024 Datenpunkten im Bereich des Übergang zum Rattern.


Datenpunkte 550096-551119:




Datenpunkte 551120-552143:




Datenpunkte 552144-553167:




Datenpunkte 553168-554191:



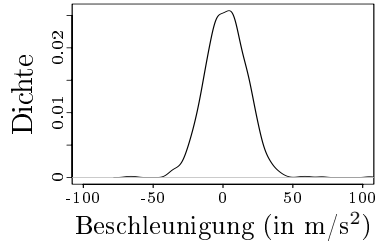
Datenpunkte 554192-555215:




Datenpunkte 555216-556239:



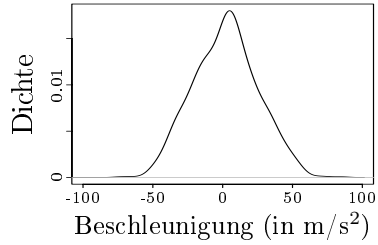
Datenpunkte 556240-557263:




Datenpunkte 557264-558287:




Datenpunkte 558288-559312:




Datenpunkte 559312-560335:




Datenpunkte 560336-561359:




Datenpunkte 561360-562383:



Datenpunkte 562384-563407:



Datenpunkte 563408-564431:



Datenpunkte 564432-565455:




Abbildung 7: Geschätzte Dichtefunktionen über je 1024 Datenpunkten im Bereich des Übergangs zum Rattern.

Auch mit Hilfe von Dichten in einem Zeitfenster ist der Übergang also charakterisierbar. Es bleibt festzuhalten, dass die Dichtefunktion im Gegensatz zur Spektrenbetrachtung und zur Betrachtung der ACF erst später zur Identifikation von Rattern neigt.

3.2.4 Identifizierung des Übergangs

Die in den vorhergehenden Kapiteln dargestellten Analysen geben einen Überblick über die Veränderungen beim Übergang zum Rattern. Die durchaus unterschiedlichen Methoden zeigen im Wesentlichen ein einheitliches Bild bezüglich des Zeitpunkts erster Ratteranzeichen. Alle Verfahren weisen den Übergang durch signifikante Veränderungen aus. Besonders bemerkenswert ist, dass diese Modifikationen schon deutlich vor dem eigentlichen Amplitudenanstieg (etwa ab Datenpunkt 560000, vgl. Abbildung 2) sichtbar werden. Die ACF kündigt den Übergang etwa 4000 Datenpunkte eher, also mehr als zwei Bohrumdrehungen vor dem eigentlichen Amplitudenanstieg an. Etwas später sind auch erste Anzeichen den Fourierspektren und den Dichten zu entnehmen.

Am Übergang selbst findet eine deutliche Veränderung der Charakteristik der Beschleunigung statt. Alle Untersuchungen weisen im ratterfreien Bereich einen periodischen Prozess mit starken, normalverteilten Störungen aus. Beim Übergang nimmt die periodische Komponente deutlich zu, so dass diese im Rattern dominant ist.

4 Modellierung und Prädiktion

Im vorhergehenden Kapitel wurde eine Beschreibung und Analyse der Daten mit unterschiedlichen statistischen Methoden vorgenommen. Nun wenden wir uns einer Modellierung des Bohrprozesses zu. Eine erfolgreiche Modellierung berücksichtigt die wesentlichen Prozesscharakteristiken. Daher ist es nach einer erfolgreichen Modellierung möglich, aus den verwendeten Modellen auf Eigenschaften des zu Grunde liegenden Bohrprozesses zurück zu schließen. An dieser Stelle betrachten wir nur die Modellierung der ratterfreien Phase, da das Rattern in geeigneter Weise durch Schwingungsmodelle beschreibbar zu sein scheint. Als Maß für die Modellgüte verwenden wir die Fähigkeit zur Prädiktion eines späteren Wertes des Prozesses.

Zur Modellierung und Prädiktion verwenden wir zwei prinzipiell unterschiedliche Ansätze. Da viele der bisherigen Ergebnisse ein nahezu lineares Prozessverhalten implizieren, setzen wir zunächst häufig verwendete lineare Modelle, die ARMA-Modelle, ein. Anschließend bearbeiten wir das gleiche Problem mit neuronalen Netzen, einer Klasse nichtlinearer Modelle. Die Ergebnisse zeigen, dass die neuronalen Modelle nur eine geringfügig bessere Modellierung ermöglichen.

4.1 Vorgehensweise

4.1.1 Datenvorverarbeitung

Als Modellierungsgrundlage dienen hier wiederum die Daten des Beschleunigungssensors beim Versuch mit der Schnittgeschwindigkeit $v_c = 100$ m/min und dem Vorschub pro Umdrehung von $f = 0.12$ mm. Die verwendeten Datensätze bestehen jeweils aus 3000 aufeinander folgenden Datenpunkten. Diese Sequenzen entstammen dem ratterfreien Teil des Prozesses, beginnend ab dem 110000. Datenpunkt, was einem Zeitpunkt von etwa 7.3 s nach Beginn der Bohrung und einer Bohrtiefe von 7.8 mm entspricht. Für die Versuche werden insgesamt 3 Datensätze von jeweils 3000 Zeitpunkten verwendet, der *Trainings-*, der *Validierungs-* und der *Testdatensatz*, welche in dieser Reihenfolge der Gesamtsequenz entnommen wurden. Für die Aufwärmphase der ARMA-Modelle und der neuronalen Netze werden jeweils die 100 Datenpunkte verwendet, welche unmittelbar vor der entsprechenden Sequenz im Prozess gemessen wurden.

Wenige Messwerte überschreiten sehr deutlich eine Schwelle von etwa 20 m/s²; zur Erhöhung der Modellierbarkeit des Gesamtprozesses werden diese Werte durch den letzten Wert der Zeitreihe, welcher im Intervall $[-20$ m/s², 20 m/s²] lag, ersetzt. Anschließend werden die Daten derart linear transformiert, dass deren Maximal- und Minimalwert genau 0.7 und -0.7 beträgt.

4.1.2 Modellanpassung

Als Maß für die Modellgüte wird im Folgenden die *Prädiktion* der Beschleunigung zu einem späteren Zeitpunkt verwendet. Ausgehend von einem aktuellen Wert $x(t)$ stellen die Modelle eine Schätzung $\hat{x}(t + \Delta t)$ bereit. Ziel der Modellanpassung ist die Optimierung der Güte der Schätzung, d. h. die Minimierung der Abweichung zwischen $\hat{x}(t + \Delta t)$ und dem tatsächlichen Wert $x(t + \Delta t)$, gemessen durch den mittleren quadratischen Fehler

$$e = \frac{1}{N} \sum_{t=0}^{N-1} (\hat{x}(t + \Delta t) - x(t + \Delta t))^2 \quad . \quad (1)$$

Dieser Fehler wird über die $N = 3000$ Prädiktionsschritte gemittelt, die in einem Datensatz zusammengefasst sind.

Zur Anpassung der Modellparameter wird der iRprop⁺-Algorithmus (Igel und Hüsken, 2000) verwendet, ein effizientes gradientenbasiertes Optimierungsverfahren¹. Zur Verhinderung der Überanpassung der Modelle verwenden wir beim Trainieren zwei Datensätze: Der zur Parametermodifikation benötigte Gradient wird mittels des Trainingsdatensatzes berechnet, wohingegen das Modell mit dem geringsten Fehler auf dem Validierungsdatensatz als das beste Netz angenommen wird. Mit dem bis dahin noch nicht verwendeten Testdatensatz wird die Leistung dieses Netzes im Nachhinein bewertet.

¹Im Zusammenhang mit neuronalen Netzen wird diese Optimierung häufig als *Training* oder *Lernen* bezeichnet.

ARMA(p, q)	Fehler $e^{(\text{train})}$	Fehler $e^{(\text{test})}$
AR(5) = ARMA(5,0)	0.0589	0.0675
AR(9) = ARMA(9,0)	0.0572	0.0669
MA(5) = ARMA(0,5)	0.0596	0.0676
MA(9) = ARMA(0,9)	0.0579	0.0667
ARMA(1,1)	0.0619	0.0687
ARMA(2,2)	0.0611	0.0688
ARMA(3,3)	0.0580	0.0669
ARMA(4,4)	0.0559	0.0644
ARMA(5,5)	0.0559	0.0644
ARMA(6,6)	0.0559	0.0644

Tabelle 1: Prädiktionsfehler verschiedener ARMA-Modelle, gemittelt über 100 Trainingsläufe. Die Fehler $e^{(\text{train})}$ und $e^{(\text{test})}$ sind auf dem Trainings- bzw. Testdatensatz bestimmt; ersterer ist der minimale Trainingsfehler während des Lernens, zweiterer der Testfehler des Modells mit dem minimalem Validierungsfehler.

4.2 Lineare Modellierung: ARMA-Modelle

Das *autoregressive moving average* (ARMA) Modell ist ein weit verbreitetes lineares, statistisches Modell zur Zeitreihenmodellierung und -prädiktion (Brockwell und Davis, 1996). Die Modellordnung wird durch die Parameter p und q beschrieben. Der beste Prognose-schätzwert im Sinne des mittleren quadratischen Fehlers für die l -Schritt-Prognose ergibt sich für ein ARMA-Modell durch

$$\hat{x}(t+l) = \sum_{j=1}^p a_j E_t[x(t+l-j)|x(t-j), j \geq 0] + \sum_{j=0}^q b_j E_t[\epsilon(t+l-j)] \quad ; \quad (2)$$

$E_t[\cdot]$ bezeichnet den Erwartungswert zum Zeitpunkt t . Für $q = 0$ ergibt sich ein reines AR(p)-Modell, für $p = 0$ ein reines MA(q)-Modell.

Da die Abweichung zwischen Schätzung und tatsächlichem Wert in die Berechnung mit eingeht, ist eine Warmlaufphase nötig, um den Einschwingvorgang des Modells abzuwarten. Nach dieser Einschwingphase kann die Abweichung zwischen Prädiktion und dem Messwert als Maß der Anpassung gewertet werden. Die Anpassung kann mit etablierten Methoden der Statistik oder aber wie hier mit anderen Parameteradaptationsverfahren durchgeführt werden. Der Algorithmus iRprop⁺ wird 300 Iterationen lang angewendet, was sich als ausreichend für die Anpassung herausgestellt hat; durch längeres Iterieren wird nur noch eine geringfügige Verbesserung auf dem Trainings- und keine Verbesserung auf dem Testdatensatz erzielt.

Zunächst wurde der Einfluss der Parameter p und q , also der Modellgröße, untersucht. Tabelle 1 gibt einen Überblick über die Abhängigkeit der Güte der 1-Schritt-Prädiktion

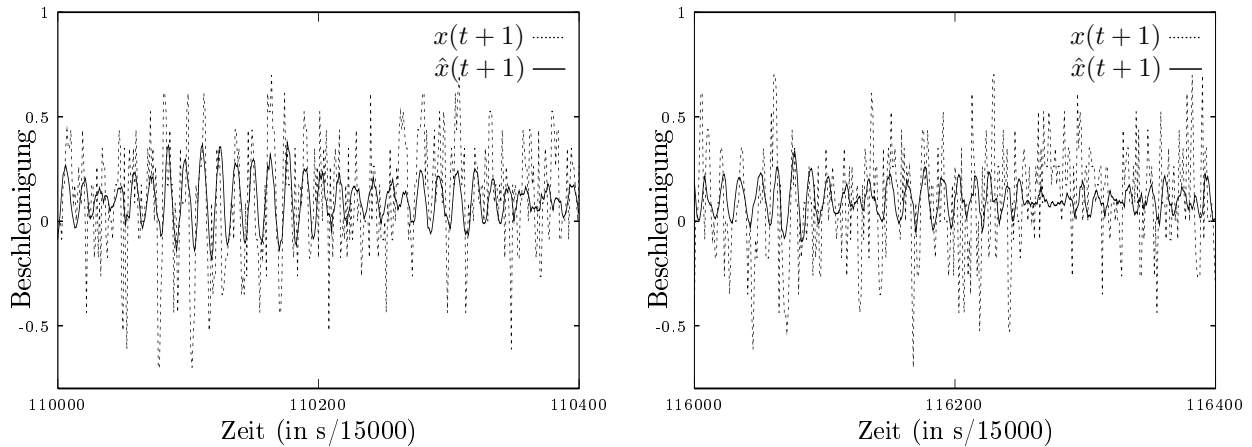


Abbildung 8: 1-Schritt-Prädiktion und Zielgröße bei einem ARMA(4,4)-Modell auf einem Ausschnitt des Trainings- (links) und Testdatensatzes (rechts).

von der Modellgröße. Die in dieser Tabelle dargestellten Ergebnisse haben sich durch Mittelung über 100 Läufe mit unterschiedlicher initialer Parameterverteilung ergeben, wobei die Standardabweichungen der Ergebnisse dieser 100 Läufe gering sind.

Verglichen mit der Varianz der Zeitreihe ($(\sigma^2)^{(\text{train})} = 0.06252$ und $(\sigma^2)^{(\text{test})} = 0.06942$), welche dem Fehler eines Schätzers entspräche, der konstant den Mittelwert der Zeitreihe ausgibt, sind die erzielten Fehler nur unwesentlich geringer. Dies liegt im Wesentlichen an der ungenügenden Modellierung der deutlichen Spitzen in der Zeitreihe (vgl. Abbildung 8). Des Weiteren ist erkennbar, dass die Modellierung mittels AR(p)- und MA(q)-Modellen zu vergleichbaren Ergebnissen führt. Eine Verbesserung der Ergebnisgüte wird durch eine Modellierung mit ARMA-Prozessen erzielt. Bis zu einer Modellgröße von etwa $p = q = 4$ steigt die Prädiktionsgüte mit der Größe an, danach ist keine weitere Verbesserung mehr festzustellen. Die 1-Schritt-Prädiktion mit dem bestangepassten ARMA(4,4)-Modell aus 100 Trainingsläufen ist in Abbildung 8 dargestellt.

Die Prädiktion offenbart einige grundlegende Eigenschaften des Prozesses und der Modellklasse: Der Prozess weist prägnante Spitzen auf, die zwar teilweise schon durch die Vorverarbeitung unterdrückt wurden, trotzdem aber noch schwer zu präzisieren sind. Des Weiteren zeigt die Prädiktion einen starken oszillatorischen Anteil des Signals. In dem Originalsignal ist dieser Anteil durch Versätze, unregelmäßige Amplitudenmodulationen und Rauschen stark gestört. Das Modell kann diesen Amplitudenschwankungen und Phasenverschiebungen relativ gut nachkommen, das restliche Rauschen bleibt dennoch hoch. Die Amplitudenspitzen lassen sich am schwierigsten modellieren.

4.3 Nichtlineare Modelle: Neuronaler Netze

Neuronale Netze stellen eine Klasse von Modellen dar, welche nichtlineare Abbildungen realisieren können und bereits vielfach bei der Lösung von Klassifikations-, Regressions- und Prädiktionsaufgaben eingesetzt wurden. Daher bieten sie sich auch hier für eine Modellierung an. Im Vergleich zu ARMA-Modellen ermöglichen sie eine Aussage, inwieweit nichtlineare Methoden die Modellierung verbessern.

4.3.1 Vorwärtsgekoppelte Neuronale Netze

Wir beschränken uns hier auf *vorwärtsgekoppelte neuronale Netze* (VNNe) mit nur einer Schicht von versteckten Neuronen; somit realisieren die hier verwendeten VNNe die Abbildung

$$\hat{x}(t + \Delta t) = \Theta + \sum_{h=1}^H v_h f(\mathbf{x}(t)\mathbf{w}_h + \Theta_h) \quad . \quad (3)$$

Die Variable H steht hierbei für die Anzahl der versteckten Neuronen und die Funktion $f(x) = \tanh(x)$ ist die nichtlineare Aktivierungsfunktion der versteckten Neuronen. Die Parameter v_h , \mathbf{w}_h , Θ_h und Θ sind die anzupassenden Modellparameter. Trotz dieser Einschränkungen besitzen die VNNe für ausreichend große Werte von N universelle Approximationseigenschaften (Hornik, Stinchcombe und White, 1989). Für eine genauere Einführung in VNNe sei auf die Bücher von Reed und Marks (1999) und Bishop (1995) verwiesen.

Da in (3) die Information lediglich vorwärts durch das Netz propagiert wird, muss die Information über zurückliegende Werte der Zeitreihe explizit durch die *Einbettung*

$$\mathbf{x}(t) = (x(t), x(t - \tau), x(t - 2\tau), \dots, x(t - (d_E - 1)\tau)) \quad (4)$$

bereitgestellt werden (Takens, 1981). Hierbei sind die *Einbettungsdimension* d_E sowie die *Zeitverzögerung* τ zu wählen. Die geeignete Verzögerung $\tau = 4$ wurde mittels der *Transinformation* bestimmt. Da das Verfahren *false nearest neighbours* zur Bestimmung der Einbettungsdimension fehlschlug, wurde in Vorversuchen die Einbettungsdimension variiert und der Wert $d_E = 8$ als geeignet bestimmt.

Des Weiteren haben wir unsere Versuche mit $H = 5$ versteckten Neuronen ausgeführt. Eine größere Topologie führte zu keinem geringeren Fehler, wohl aber zu einer stärkeren Überanpassung. Vor dem Training von 200 Iterationen Länge wurden die Gewichte aller Verbindungen zufällig mit Werten aus dem Intervall $[-0.1, 0.1]$ initialisiert.

4.3.2 Rückgekoppelte Neuronale Netze

Im Gegensatz zu VNNe wird bei *rückgekoppelten neuronalen Netzen* (RNNen) die Information nicht nur vorwärts vom Ein- zum Ausgang durch das Netzwerk propagiert, sondern

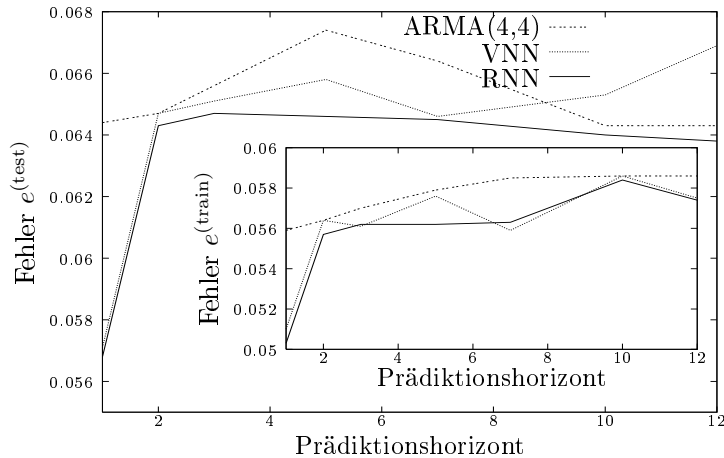


Abbildung 9: Vergleich der Prädiktionsfehler unterschiedlicher Modelle bei unterschiedlichem Prädiktionshorizont. Die Ergebnisse sind über 100 Läufe gemittelt, wobei die Standardabweichungen innerhalb der Läufe geringer als die typischen Unterschiede der verschiedenen Modelle sind.

zusätzlich mittels Rückkopplungen zurückgeführt. Daher bildet ein RNN ein dynamisches System, dessen Ausgabe nicht nur von der aktuellen Eingabe, sondern auch vom internen Zustand bestimmt wird; mit ähnlicher Begründung wie bei den ARMA-Prozessen ist daher auch bei den RNNen eine Aufwärmphase notwendig. Aufgrund der Rückkopplungen kann auf eine explizite Einbettung verzichtet werden; vielmehr realisiert ein geeignet trainiertes RNN eine implizite Einbettung (Stagge und Sendhoff, 1999), indem es sich die relevanten älteren Informationen selbst bereitstellt.

Als Basisstruktur verwenden wir erweiterte Elman-Netze (Stagge und Sendhoff, 1997) mit 10 versteckten Neuronen und einer Gedächtnisschicht. Bei Vorversuchen hat sich diese Größe als geeignet für das vorliegende Problem herausgestellt. Wie bei den VNNen wurden die Gewichte vor dem Training zufällig mit Werten aus dem Intervall $[-0.1, 0.1]$ initialisiert und ein Training vom maximal 200 Iterationen Länge durchgeführt.

4.4 Vergleich zwischen linearer und nichtlinearer Modellierung

In Abbildung 9 ist der Trainings-, bzw. Testfehler der unterschiedlichen Modelle in Abhängigkeit vom Prädiktionshorizont dargestellt. Das Verhalten aller Modelle ist prinzipiell ähnlich auf dem Trainings- und Testdatensatz, lediglich der absolute Fehler unterscheidet sich etwa in dem Maße, in welchem sich auch die Varianz der einzelnen Datensätze unterscheidet ($(\sigma^2)^{(train)} = 0.06252$ und $(\sigma^2)^{(test)} = 0.06942$). Des Weiteren sind die Fehler auch für große Prädiktionshorizonte geringer als die Varianz.

Die RNNen erzielen bei allen Aufgaben die besten Ergebnisse; für kleine Prädiktionshorizonte dicht gefolgt von den VNNen, für große Horizonte sind die ARMA-Modelle

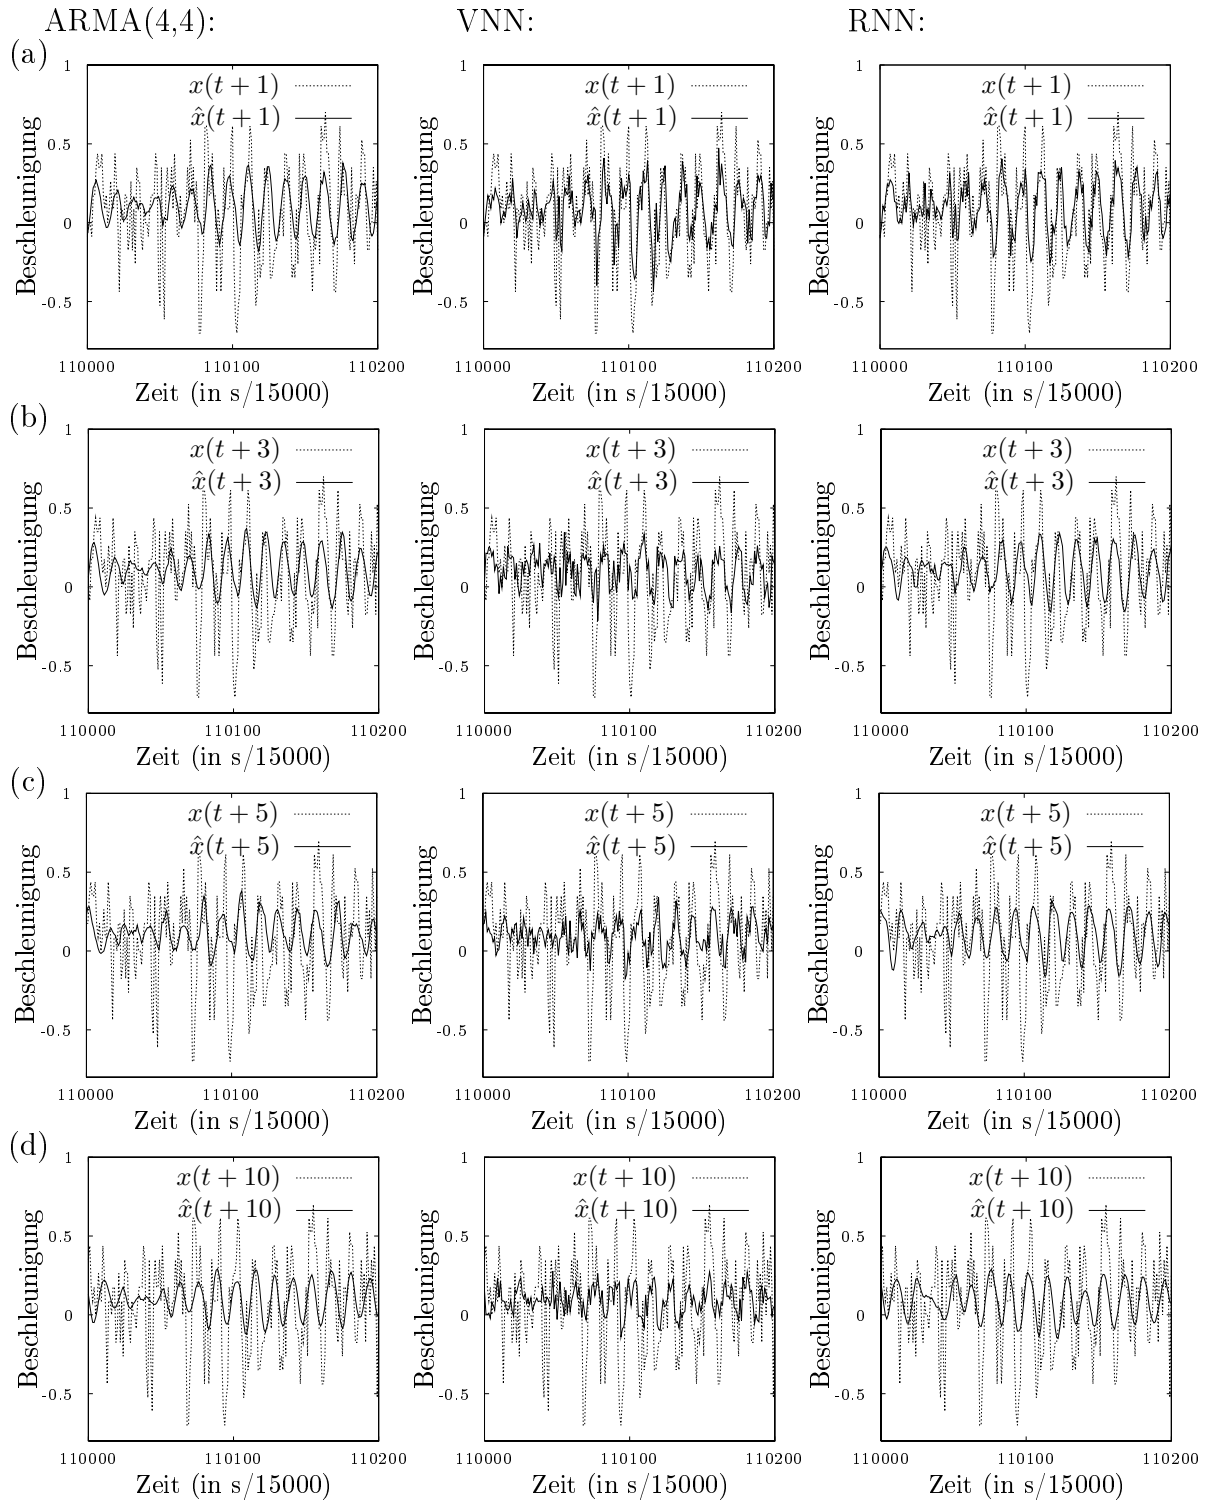


Abbildung 10: Prädiktionsergebnisse bei einer n -Schritt-Prädiktion (a: $n = 1$, b: $n = 3$, c: $n = 5$, d: $n = 10$) mit Hilfe unterschiedlicher Modelle. Alle Ergebnisse sind auf dem Trainingsdatensatz erzielt.




Abbildung 11: Fourierspektren der Modelle für die 5-Schritt-Prädiktion im ratterfreien Bereich.

nur geringfügig schlechter. Dieses Ergebnis deutet darauf hin, dass bei der 1-Schritt-Prädiktion die nichtlinearen Elemente der neuronalen Netze effizient eingesetzt werden können. Aber schon ab einer 2-Schritt-Prädiktion scheint die lineare Modellierung nur unwesentlich schlechter zu sein. Vielmehr stellt sich hier sogar die Modellierung mittels VNNe als am ungünstigsten heraus, was allerdings vielfältige Gründe haben kann: Zum einen deuten die Ergebnisse auf eine leichte Überanpassung der VNNe hin, zum anderen könnten die schlechten Ergebnisse auch Konsequenz einer nicht optimalen expliziten Einbettung sein.

Abbildung 10 gibt einen Eindruck über die Art der Abweichungen der von den Modellen prädizierten Werte von den Sollwerten des Trainingsdatensatzes. Es ist erkennbar, dass alle Modelle, insbesondere aber die ARMA-Modelle und die RNNe, ein periodisches Verhalten prädizieren (siehe hierfür auch die Fourierspektren der Modelle in Abbildung 11). Die Wellenlänge der Schwingungen stimmt in etwa mit der markanten Frequenz aus Abbildung 3 und der Grundfrequenz beim hochfrequenten Rattern (Abbildung 4, links) überein, welche bereits als eine Eigenschwingung des Bohrers identifiziert wurde.

Dieses stark periodische Verhalten wird bei kurzen Prädiktionshorizonten durch die Auflösung einzelner Details ergänzt, besonders stark ist diese Detailauflösung bei den VNNe zu erkennen.

5 Diskussion

Das BTA-Tiefbohren stellt ein Verfahren zur Erzeugung tiefer Bohrungen dar. Aufgrund dieser Randbedingungen können während des Bohrbetriebes unerwünschte Zustände wie Rattern auftreten, die mit einer starken Beanspruchung oder Zerstörung des Werkstücks und des Werkzeugs einhergehen. Daher stellt die frühzeitige Identifikation dieser Zustände und die Organisation eines Eingriffs in den Prozess ein wesentliches Ziel dar. Zur Gewinnung von Schlüssen über die Charakteristik des Tiefbohrprozesses haben wir Daten, die bei einem solchen Bohrprozess direkt am Bohrkopf aufgezeichnet wurden, mit Methoden der mathematischen und statistischen Zeitreihenanalyse untersucht.

Von besonderem Interesse war bei der Analyse der Übergang vom ratterfreien in den ratterbehafteten Zustand. Dieser Übergang fällt mit einer betragsmäßig deutlichen Beschleunigungszunahme zusammen. Vor dem Übergang erscheint der Prozess als stark verrauscht mit einem geringen periodischen Anteil, wohingegen die Phase nach dem Übergang durch stark regelmäßiges und periodisches Verhalten geprägt ist.

Diese ersten Beobachtungen werden durch exaktere Analysen gestützt und erweitert. Eine Fourieranalyse bestätigt die Existenz der periodischen Anteile im gesamten Prozess, also auch in der ratterfreien Phase. Die Grundfrequenz entspricht der Torsionseigenfrequenz des Bohrers. Beim Übergang zum Rattern tritt diese Frequenz deutlich stärker im Spektrum hervor und wird durch eine Vielzahl von Oberschwingungen ergänzt, deren Stärke nur langsam mit zunehmender Ordnung abnimmt. Des Weiteren wird durch die Frequenzanalyse zu einem späteren Zeitpunkt eine Phase mit deutlich geringerer Grundfrequenz identifiziert. Diese charakteristischen Ratterfrequenzen entsprechen zwei der sieben Eigenfrequenzen der Bohrstange.

Die Beobachtung der statistischen Verteilungsdichte der Daten in kurzen Zeitfenstern zeigt, dass die ratterfreie Phase im Wesentlichen durch einen eingipfligen, symmetrischen, vergleichsweise normalverteilten Zufallsprozess geprägt ist, wohingegen wieder der periodische Charakter im Rattern sichtbar wird. Zu vergleichbaren Ergebnissen gelangen wir auch durch Berechnung der Autokorrelationsfunktionen im Zeitfenster. Insbesondere diese liefern starke Hinweise, dass der Bohrprozess mit guter Genauigkeit linear modellierbar ist (z. B. mit ARMA-Prozessen oder harmonischen Schwingungen). Gerade die Annahme der linearen Modellierbarkeit im ratterfreien Bereich bestätigte sich beim Vergleich der Güte der linearen Modellierung mit nichtlinearen Modellierungsmethoden mittels vorwärts- und rückgekoppelter neuronaler Netze zum Zwecke der Prädiktion des Prozesses. Der notwendige nächste Schritt wird die Modellierung des Übergangs sein, um weitere Erkenntnisse über die Entstehung des Ratterns zu erlangen.

Alle Ergebnisse charakterisieren das Verhalten der Beschleunigung als näherungsweise linear und stark durch die Eigenfrequenz des Bohrers dominiert. Des Weiteren erscheinen die Maße geeignet, um die unterschiedlichen Phasen (ratterfrei / ratterbehaftet) von einander abzugrenzen und den Übergang zu identifizieren. Gerade der letzte Aspekt ist wesentlich, um den Eingriff in den Prozess zur Abwendung des Ratterns möglichst frühzeitig zu ermöglichen.

Danksagung

Wir danken der DFG, die dieses Forschungsprojekt im Rahmen des SFB 475 „Komplexitätsreduktion in multivariaten Datenstrukturen“ fördert. Für die hilfreichen Diskussionen während der Erstellung der Ergebnisse bedanken wir uns herzlich bei Prof. W. von Seele. Des Weiteren danken wir den Mitarbeitern des Instituts für spanende Fertigung an der Universität Dortmund für die Bereitstellung der Daten sowie für die kooperative Zu-

sammenarbeit. Unseren Korrekturlesern C. Ronnewinkel und Prof. C. Weihs sei an dieser Stelle ebenfalls großer Dank für die kritischen Anmerkungen ausgesprochen.

Literatur

- Bishop, C. M. (1995). *Neural Networks for Pattern Recognition*. Oxford: Oxford University Press.
- Brockwell, P. J. und R. A. Davis (1996). *Introduction to Time Series and Forecasting*. New York: Springer.
- Hornik, K., M. Stinchcombe und H. White (1989). Multilayer feedforward networks are universal approximators. *Neural Networks* 2, 359–366.
- Igel, C. und M. Hüsken (2000). Improving the rprop learning algorithm. In H.-H. Bothe und R. Rojas (Hrsg.), *Proceedings of the Second International ICSC Symposium on Neural Computation (NC 2000)*, S. 115–121. ICSC Academic Press.
- Kendall, M. und J. K. Ord (1990). *Time Series* (3 Aufl.). Suffolk: Edward Arnold.
- Reed, R. D. und R. J. Marks (1999). *Neural Smithing*. Cambridge: The MIT Press / Bradford Books.
- Stagge, P. und B. Sendhoff (1997). An extended elman net for modeling time series. In W. Gerstner, A. Germond, M. Hasler und J. Nicoud (Hrsg.), *Artificial Neural Networks (ICANN '97)*, Band 1327 aus *Lecture Notes in Computer Science*, S. 427–432. Springer Verlag.
- Stagge, P. und B. Sendhoff (1999). Organisation of past states in recurrent neural networks: Implicit embedding. In M. Mohammadian (Hrsg.), *Computational Intelligence for Modelling, Control & Automation*, S. 21–27.
- Takens, F. (1981). Detecting strange attractors in turbulence. In D. Rand und L. S. Young (Hrsg.), *Dynamical Systems and Turbulence*, Band 898 aus *Lecture Notes in Mathematics*, S. 366–381. Springer Verlag.
- VDI-Richtlinie 3210 (1974, Juni). Tiefbohrverfahren. VDI Düsseldorf.
- Webber, O. (1999). Meßtechnische Erfassung und Analyse dynamischer Instabilitäten des BTA-Tiefbohrprozesses. Diplomarbeit, Institut für Spanende Fertigung, Fakultät für Maschinenbau, Universität Dortmund, 44227 Dortmund, Deutschland.
- Weinert, K., O. Webber, A. Busse, M. Hüsken, J. Mehnen und P. Stagge (2001). In die Tiefe: Koordinierter Einsatz von Sensorik und Statistik zur Analyse und Modellierung von BTA-Tiefbohrprozessen. *Zeitschrift für wirtschaftlichen Fabrikbetrieb*.