

# TRANSKRIPTION VON SCHLAGZEUGAUFNAHMEN UNTER VERWENDUNG DES UASR-SYSTEMS.

*Stephan Hübler, Johannes Völkner and Rüdiger Hoffmann*

*TU Dresden - Professur für Systemtheorie und Sprachtechnologie*

*stephan.huebler@tu-dresden.de*

**Kurzfassung:** Die Transkription von Musiksignalen, daher die Überführung von Audiomaterial in eine symbolische Repräsentation, stellt eine Herausforderung im Forschungsbereich Music Information Retrieval dar. Der vorliegende Beitrag beschreibt die automatische Transkription unterschiedlicher Trommeln und Becken in Schlagzeugaufnahmen. Die Aufgabe der Transkription ist es folgende Frage zu beantworten: Was wird wann gespielt? Es werden zwei verschiedene Ansätze zur Beantwortung dieser Fragen präsentiert. Der Ansatz Segmentierung und Klassifizierung teilt das Audiosignal in bedeutungsvolle Einheiten, welche anschließend klassifiziert werden, womit zunächst das wann und anschließend das was beantwortet wird. Der zweite Ansatz verwendet ein Erkennungsnetzwerk mit Hidden Markov Modellen, womit die Frage nach dem wann und was simultan beantwortet wird. Für die Evaluierung werden zwei Datenbanken verwendet: eine MIDI-Datenbank mit synthetisch erzeugten Schlagzeugsignalen und die frei verfügbare Datenbank ENST-Datenbank mit realen Schlagzeugaufnahmen. Für das Training, die Erkennung und die Evaluierung wird das Open Source UASR-System (*Unified Approach for Signal Analysis and Recognition*) verwendet, womit dessen Einsatzmöglichkeit für musikalische Signale gezeigt werden kann.

## 1 Einleitung

Die vollständige automatische Transkription von Musik ist noch nicht vollständig gelöst. Emmanouil Benetos gibt einen Überblick über Ansätze der Transkription und schlägt Verbesserungsmöglichkeiten vor [3]. Potential für Verbesserungen sieht er bei semi-automatische Ansätzen oder in der Spezialisierung der Transkription auf spezielle Anwendungsfälle. Die Erkennung von Trommeln und Becken in Schlagzeugaufnahmen ist ein solcher Spezialfall, dessen Lösung zu einer kompletten Transkription von Musikstücken mit mehreren gleichzeitig spielenden Instrumenten beiträgt [8, 15]. Darüber hinaus ist die Transkription von Trommeln und Becken in Schlagzeugaufnahmen besonders interessant für die Indizierung und Organisation von kurzen Schlagzeugaufnahmen (Drum Loops) in Musikproduktionssystemen, der Suche nach Rhythmen durch Beatboxing oder Sprache, der Umstrukturierung von Schlagzeugspuren (Remixing), als Übungshilfe für den Schlagzeuger, der Erzeugung neuer Schlagzeugrhythmen und automatischer Genreerkennung.

Bei der Transkription sind prinzipiell zwei Fragen zu beantworten: Wann wird etwas gespielt und was wird gespielt? Die Reihenfolge in der diese Fragen beantwortet werden, ergibt drei mögliche Strategien der Transkription: (1) Segmentierung und Klassifikation, (2) Trennung und Klassifikation und (3) Simultane Segmentierung und Klassifikation.

**1. Segmentierung und Klassifikation:** Bei der Strategie der Segmentierung und Klassifikation wird zunächst die Frage wann etwas gespielt wird beantwortet und anschließend die Frage, welches Instrument. Dabei wird die Schlagzeugaufnahme zunächst in bedeutungsvolle Einheiten unterteilt. Dies kann durch Algorithmen der Anschlagerkennung erfolgen [11], oder aber durch die Verwendung eines musikalischen Rasters wie dem schnellsten Puls [17]. Aus den Segmenten werden Merkmale erstellt, entweder in dem das Analysefenster das gesamte Segment umfasst [12], oder aber kleinere Zeitfenster innerhalb des Segmentes gebildet werden und dann deren Mittelwert für die anschließende Klassifikation verwendet wird [9]. Als Klassifikatoren werden Support Vector Machines [9], Gaussian Mixture Models [17] oder auch Clustering und Entscheidungsbäume verwendet [12].

**2. Trennung und Klassifikation:** Die Strategie der Trennung und Klassifikation trennt zunächst die einzelnen zu detektierenden Schlagzeuginstrumente im Signal in einzelne Audioströme [7]. Dafür werden Verfahren wie Independent Subspace Analysis (ISA) [18], Prior Subspace Analysis (PSA) [5] oder Non-negative factor matrix factorisation [4] verwendet. Es wird zunächst die Frage was gespielt wird beantwortet, um im zweiten Schritt in den einzelnen Audioströmen die Anschläge zu detektieren und die Frage wann eine Instrument gespielt wird zu klären. Idealerweise beinhalten die einzelnen Audioströme nur noch eine Trommel.

**3. Simultane Segmentierung und Klassifikation:** Eine simultane Segmentierung und Klassifikation ist bei der Verwendung von Hidden Markov Modellen möglich, wenn die verschiedenen Modelle der einzelnen Instrumente zu einem Erkennungsnetzwerk verknüpft werden [16]. Bei der freien Erkennung kann dann die Bestimmung der Anschlagszeitpunkte und die Klassifikation der einzelnen Noten gleichzeitig durchgeführt werden.

Der vorliegende Beitrag untersucht die Strategien (1) und (3) unter Verwendung des UASR-Systems [14].

## 2 Datenbanken

Für die Evaluierung des Systems ist eine annotierte Datenbank nötig, daher Aufnahmen zu denen zeitliche Annotationen der zu klassifizierenden Trommeln und Becken existieren. Im Zuge dieser Arbeiten werden dazu die Schlagzeugspuren aus 100 MIDI-Dateien mit 10 unterschiedlichen Soundbänken (soundfonts) synthetisiert. Dadurch wird zumindest in geringem Maße der Klang der einzelnen Trommeln und Becken variiert. Die Dateien sind Teil der midiart Datenbank<sup>1</sup>, wobei das P100 für „Playground“ mit 100 Dateien steht. Die Schlagzeugspuren bestehen nur aus den fünf zu klassifizierenden Schlagzeugkategorien Bass Drum (35, 36), Snare Drum (37, 38, 40), Hi Hat (42, 44, 46), Ride (51, 53, 59) und Cymbals (49, 52, 55, 57), hier mit den dazugehörigen Noten in der General Midi Drum Map angegeben. Die nötige Annotation der einzelne gespielten Trommeln kann dann aus der MIDI-Datei ausgelesen werden. Die Anzahl der einzelnen Noten pro Kategorie ist in Tabelle 1 aufgeführt.

Um das System mit realen Schlagzeugdaten zu testen, wird außerdem die frei verfügbare ENST-Datenbank verwendet [10]. Dabei handelt es sich um Schlagzeugaufnahmen von drei verschiedenen Schlagzeugern. Für die Evaluierung werden die minus-one (MO) Titel verwendet, bei denen die Schlagzeuger frei zu Begleitmusik spielen konnten. Die Begleitmusik wird für die weitere Erkennung ausgeblendet. Es existieren je 21 bis 22 Titel pro Schlagzeuger mit einer Länge von 30 - 75 s. Für die Evaluierung wird der „wet“-Mix verwendet, eine Abmischung der einzelnen Komponenten des Schlagzeugs, wie er in kommerziellen CDs üblich ist. Im Unterschied zur P100-Datenbank enthalten diese Aufnahmen auch Trommeln wie die Toms, welche

---

<sup>1</sup>[www.midi.de](http://www.midi.de)

Kategorie	P100	ENST-MO
Bass Drum	34.627	10.686
Snare Drum	28.425	11.630
Hi Hat	74.915	14.158
Ride	3.938	3.117
Cymbal	2.736	328

**Tabelle 1** - Anzahl der Ereignisse pro Schlagzeugkategorie für die zwei verwendeten Datenbanken P100 und ENST (Minus-One-Tracks).

nicht evaluiert werden. Auch andere Autoren verwenden diese Datenbank, was einen Vergleich möglich macht [11, 16].

### 3 Systembeschreibung

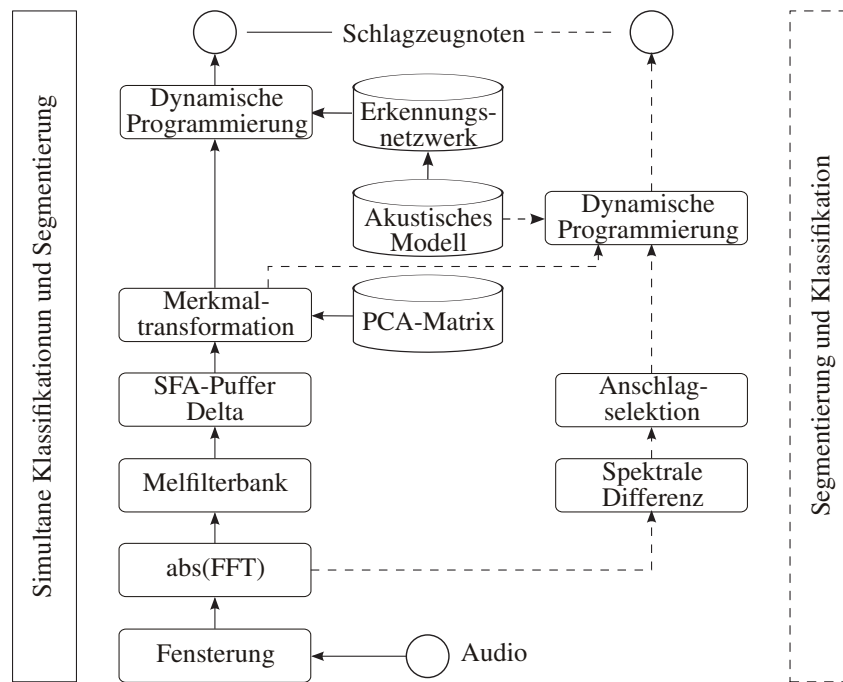
Das prinzipielle Vorgehen der Transkription von Schlagzeugspuren wurde bereits in [13] vorgestellt. Aus den Schlagzeugaufnahmen mit einer Abtastrate von 44,1 kHz werden zunächst Merkmale errechnet. Die einzelnen Analysefenster haben eine Breite von 2.048 und eine Fortsetzrate von 512 Abtastwerten. Nach der Multiplikation mit der Blackman Fensterfunktion wird das Amplitudenspektrum  $X_n(l)$  mit  $n$  Spektrallinien für jedes Fenster  $l$  berechnet. Für das Training der akustischen Modelle und der späteren Erkennung wird auf das Spektrum eine Melfilterbank mit 30 Kanälen angewendet. Nach der Logarithmierung, Normalisierung und der Berechnung der  $\Delta$ -Merkmale kommt als sekundäre Merkmalanalyse die Hauptkomponentenanalyse zum Einsatz. Die Merkmale sind damit denen von Jouni Paulus ähnlich [16].

Ebenfalls Jouni Paulus folgend, wird für jede der fünf Schlagzeugkategorien ein Detektorklassifikator erstellt. Für die einzelne Kategorie wird ein Hidden-Markov-Modell mit drei Zuständen erstellt. Im Trainingsmaterial sind die Zeitpunkte der einzelnen Kategorien markiert und die nächsten 13 Merkmalvektoren (151 ms) werden dem entsprechenden Modell zugeordnet, es sei denn, dass nächste Ereignis der gleichen Kategorie tritt vorher auf. Dann gehen nur die Merkmalvektoren bis zu dem nächsten Ereignis ein. Alle anderen Merkmalvektoren werden einem Gaussian Mixture Modell, dem Modell aller anderen Ereignisse im Musiksinal zugeordnet. Pro Kategorie entsteht somit ein Klassifikator mit je zwei akustischen Modellen – eines für die entsprechende Kategorie und eines für den Rest.

Die zwei unterschiedlichen Vorgehensweisen bei der Erkennung ist in Abbildung 1 dargestellt. Bei der simultanen Klassifikation und Erkennung werden die zwei akustischen Modelle einer Kategorie zu einem Erkennungsnetzwerk zusammengefasst und mittels dynamischer Programmierung der beste Weg für eine unbekannte Merkmalvektorfolge für jede Kategorie einzeln ermittelt. Bei dem Ansatz der Segmentierung und Klassifikation werden zunächst die Anschläge im Musiksinal verwendet. Dazu wird die spektrale Differenz zweier aufeinanderfolgender Zeitfenster ermittelt. Es werden nur positive Differenzen berücksichtigt, um den Fokus auf den Anschlag und nicht das Abklingen eines Tones zu legen.

$$\text{SDP}(l) = \sum_{n=0}^{N-1} H(|X_n(l+1)| - |X_n(l)|) \quad (1)$$

$$H(x) = \frac{x + |x|}{2} = \begin{cases} 0 & : x \leq 0 \\ x & : x > 0 \end{cases} \quad (2)$$



**Abbildung 1** - Ablauf der zwei Vorgehensweisen in der Erkennung von Schlagzeugnoten.

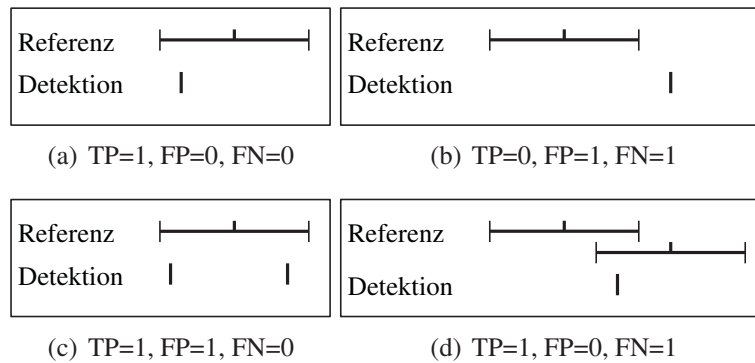
Nach der Anschlagselektion, der Ermittlung der Maxima, liegen die möglichen Zeitpunkte eines Ereignisses im Musiksignal vor [2]. In einem zweiten Schritt wird nun ermittelt, ob die jeweilige Schlagzeugkategorie für den jeweiligen Anschlag vorliegt. Dazu werden ab jedem Anschlag die 13 folgenden Merkmalvektoren, entsprechend weniger sollte der nächste Anschlag vorher auftreten, verwendet und ermittelt, ob diese Merkmalvektoren besser zu dem Modell der jeweiligen Kategorie oder dem Restmodell passen.

Grundlegend für die Evaluierung der Algorithmen ist die Zuordnung der erkannten Anschläge zu den Referenzanschlägen. Es folgen die in der Literatur üblicherweise verwendeten Begriffe:

- **True Positive (TP):** Für einen Referenzanschlag wird innerhalb des Toleranzzeitfensters ein Anschlag detektiert.
- **False Negative (FN):** Für einen Referenzanschlag wird im Toleranzzeitfenster kein Anschlag detektiert.
- **False Positive (FP):** Es wird ein Anschlag detektiert, der in kein Toleranzzeitfenster eines Referenzanschlages fällt.

Bei der Evaluierung werden Referenz und ermittelte Anschläge miteinander verglichen. Der Toleranzbereich um einen Referenzanschlag ist  $\pm 23$  ms. Abbildung 2 verdeutlicht mögliche Konstellationen zwischen Anschlägen in der Referenz und der Detektion. Es kann pro Referenzschlag nur eine Detektion geben (Fall (c) wird in der Literatur oft als doubled bezeichnet) und auch jede Detektion kann nur einer Referenz zugeordnet werden (sollten zwei Referenzen in Frage kommen, wird das in der Literatur als merged bezeichnet – Fall (d)) [1, 6].

Als Kenngrößen zur Bewertung und Vergleich von Algorithmen der Anschlagerkennung sind die Angabe von Recall, Precision und F-Measure üblich. Der Recall gibt an, wie viel der Refe-



**Abbildung 2** - Festlegung von True Positive (TP), False Positive (FP) und False Negative (FN) für verschiedene Konstellationen von Referenzanschlügen und erkannten Anschlügen. Für den Referenzanschlag ist der Toleranzbereich mit eingezeichnet.

renzanschlüge tatsächlich erkannt wurden.

$$\text{Recall} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Negative}} \quad (3)$$

Die Precision gibt an, wie viel der erkannten Anschläge auch tatsächlich in der Referenz vorhanden sind.

$$\text{Precision} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Positive}} \quad (4)$$

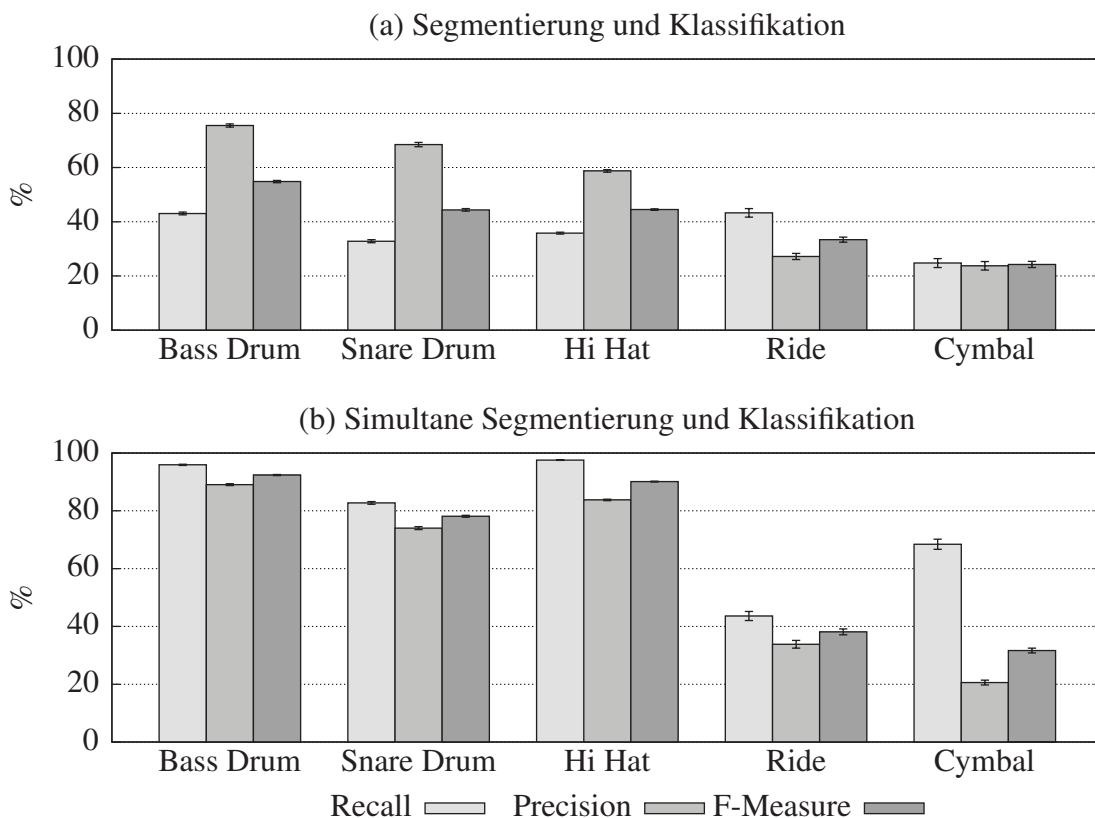
Sowohl Recall als auch Precision sollten für einen guten Algorithmus hohe Werte annehmen. Für die Bewertung des Systems durch einen skalaren Wert, hat sich der F-Measure als harmonisches Mittel von Recall und Precision durchgesetzt.

$$\text{F-Measure} = \frac{2 \cdot \text{Recall} \cdot \text{Precision}}{\text{Recall} + \text{Precision}} \quad (5)$$

## 4 Ergebnisse

Zunächst die Ergebnisse für die P100-Datenbank. Abbildung 3 (a) zeigt die Ergebnisse für die Klassifizierung nach dem Ansatz Segmentierung und Klassifikation. Der Recall ist für Bass Drum, Snare Drum und Hi Hat deutlich geringer als die Precision. Der höchste F-Measure wird mit 54,8 % für die Bass Drum erreicht. Aber auch dort werden nur 43,1 % der Referenzanschlüge erkannt. Deutlich besser fällt das Ergebnis für die Strategie der simultanen Erkennung durch das Hidden Markov Modell in Abbildung 3 (b) aus. Es werden 95,9 % der Bass Drum Referenzanschlüge erkannt, wobei 89,1 % der erkannten Anschläge auch tatsächlich in der Referenz vorhanden sind. Ein ähnlich gutes Ergebnis wird für die Hi Hat erreicht und ein akzeptables für die Snare Drum mit 82,8 % erkannter Referenzanschlüge. Deutlich schlechter schneiden in beiden Ansätzen das Ride und die Cymbals ab.

Für die ENST-Datenbank sind die Ergebnisse in Abbildung 4 angegeben. Auch auf der ENST Datenbank sind die Ergebnisse der simultanen Klassifikation und Segmentierung durch das Erkennungsnetzwerk besser als die getrennte Segmentierung und Klassifikation. Im Vergleich zu den synthetisch erstellten Audiospuren der P100 Datenbank sind die Ergebnisse bei echten Schlagzeugaufnahmen etwas schlechter, aber immer noch akzeptabel (Bass Drum: 75,0 %, Snare Drum 71,7 % und Hi Hat 81,2 % F-Measure). Auch hier sind die Ergebnisse für Ride und Cymbals deutlich schlechter. Die Ergebnisse unterscheiden sich zu den Experimenten von

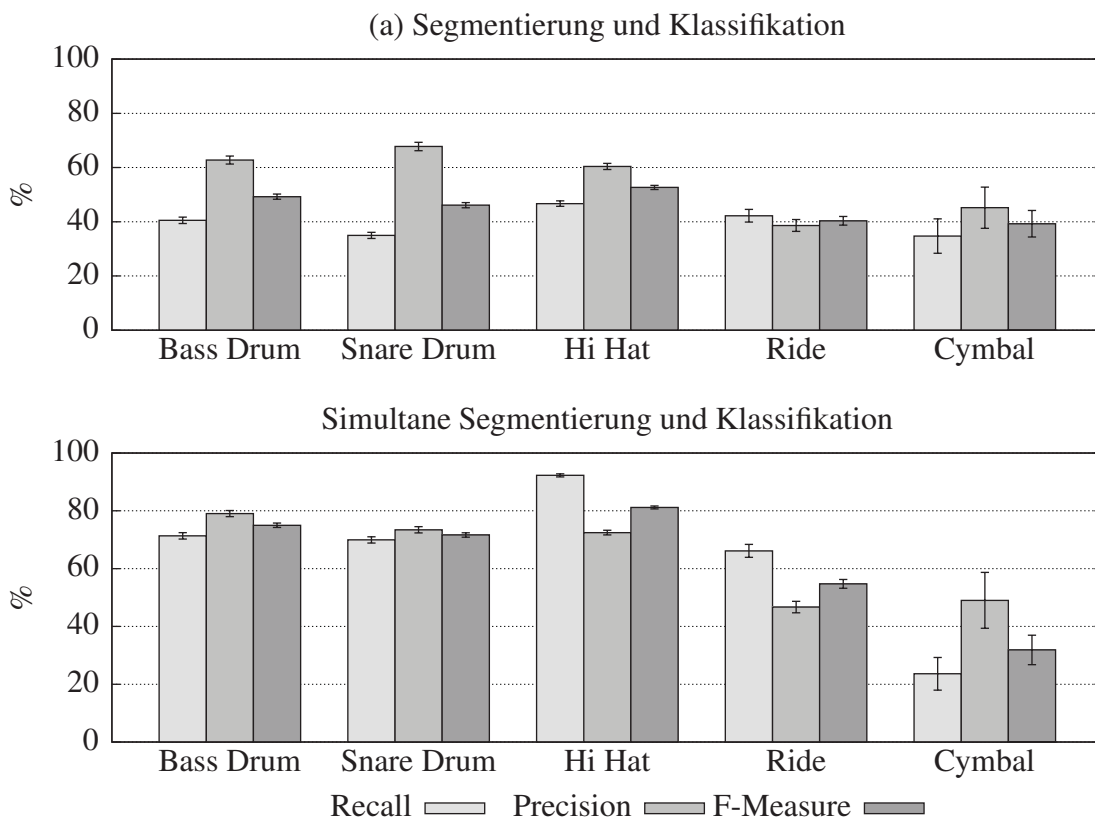


**Abbildung 3** - P100-Datenbank Ergebnisse der Evaluation mit 10facher Kreuzvalidierung und der Angabe des 95 %-Konfidenzintervall.

Jouni Paulus auf der gleichen Datenbank. Die Bass Drum wird schlechter erkannt, dagegen die Snare Drum besser und die Hi Hat hat gleiche Ergebnisse [16]. Diese Unterschied sind sicherlich in der Vielzahl der möglichen Parameter bei der Merkmalextraktion, der Modelle, des Trainings und der Evaluation begründet. Die Toleranzzeit zwischen Referenzanschlag und einem Anschlag in der Erkennung wurden im vorliegenden Beitrag gegenüber Jouni Paulus mit  $\pm 23$  ms gegenüber  $\pm 30$  ms reduziert.

## 5 Schlussfolgerungen

Eine Erkennung der Trommeln Bass Drum, Snare Drum und des Beckens Hi Hat in Schlagzeugaufnahmen ist mittels HMM-Klassifikation erfolgreich möglich. Auf realen Schlagzeugdaten (ENST-Datenbanken) werden 77,8 % der Bass Drum, Snare Drum und Hi Hat Anschläge richtig erkannt und klassifiziert. Das Ride Becken und die Cymbals werden schlecht erkannt. Ride und insbesondere die Cymbals sind im Trainingsmaterial deutlich weniger vertreten. Insbesondere die Cymbals werden fast immer mit anderen Trommeln oder Becken gleichzeitig geschlagen, so dass es für den Klassifikator schwieriger ist, die Cymbals zu separieren. Eine Verbesserungsmöglichkeit wäre die Erstellung von speziellen Merkmalen, welche insbesondere die hohen Frequenzen betonen. Zukünftige Arbeiten können den Vergleich von den hier vorgestellten Detektorklassifikatoren mit Modellen für die jeweilige Kombination der Schlagzeugkategorien vornehmen, sowie spezielle Merkmale für die einzelnen Schlagzeugkategorien entwerfen.



**Abbildung 4** - ENST-Datenbank Ergebnisse der Evaluierung mit 10facher Kreuzvalidierung und dem 95 %-Konfidenzintervall.

## Literatur

- [1] BÖCK, S., F. KREBS und M. SCHEDL: *Evaluating the online capabilities of Onset Detection Methods*. In: *ISMIR, 13th International Society for Music Information Retrieval Conference*, S. 49–54, Porto, Portugal, 2012.
- [2] BELLO, J. P., L. DAUDET, S. ABDALLAH, C. DUXBURY, M. DAVIES und M. B. SANDLER: *A Tutorial on Onset Detection in Musical Signals*. *IEEE Transactions on Speech and Audio Processing*, 13(5):1035–1047, Sep. 2005.
- [3] BENETOS, E., S. DIXON, D. GIANNOULIS, H. KIRCHHOFF und A. K LAPURI: *Automatic music transcription: challenges and future directions*. *Journal of Intelligent Information Systems*, S. 1–28, 2013.
- [4] CAVACO, S. und H. ALMEIDA: *Automatic cymbal classification using non-negative matrix factorization*. In: *Systems, Signals and Image Processing (IWSSIP), 2012 19th International Conference on*, S. 468–471, 2012.
- [5] DITTMAR, C. und C. UHLE: *Further Steps towards Drum Transcription of Polyphonic Music*. In: *Proc. of the Audio Engineering Society 116th Convention*, Berlin, Germany, 2004.
- [6] DIXON, S.: *Onset Detection Revisited*. In: *DAFx-06, 9th Int. Conference on Digital Audio Effects*, Montreal, Canada, 2006.

- [7] FITZGERALD, D.: *Automatic drum transcription and source separation*. Doktorarbeit, Dublin Institute of Technology, 2004.
- [8] FITZGERALD, D. und J. PAULUS: *Unpitched Percussion Transcription*. In: KLAPURI, A. und M. DAVY (Hrsg.): *Signal Processing Methods for Music Transcription*, S. 131–162. Springer US, 2006.
- [9] GILLET, O. und G. RICHARD: *Automatic transcription of drum loops*. In: *ICASSP, Proc. IEEE Int. Conf. on Acoustics, Speech, and Signal Processing*, Bd. 4, S. 269–272, Mai 2004.
- [10] GILLET, O. und G. RICHARD: *ENST-Drums: an Extensive Audio-Visual Database for Drum Signals Processing*. In: *ISMIR, 7th International Society for Music Information Retrieval Conference*, S. 156–159, Victoria, Canada, 2006.
- [11] GILLET, O. und G. RICHARD: *Transcription and Separation of Drum Signals From Polyphonic Music*. *Audio, Speech, and Language Processing, IEEE Transactions on*, 16(3):529–540, 2008.
- [12] GOUYON, F. und P. HERRERA: *Exploration of techniques for automatic labeling of audio drum tracks instruments*. In: *Proc. of MOSART Workshop on Current Research Directions in Computer Music*, 2001. Audio Content.
- [13] HÜBLER, S. und R. HOFFMANN: *Experimentelle Ansätze zur Schlagzeuganalyse in Musiksignalen*. In: KRÖGER, B. J. und P. BIRKHOLZ (Hrsg.): *Elektronische Sprachsignalverarbeitung. Tagungsband der 22. Konferenz, Aachen, 28. – 30. 9.*, Bd. 61 d. Reihe *Studententexte zur Sprachkommunikation*, S. 301–308, Aachen, Germany, 2011.
- [14] HOFFMANN, R., M. EICHNER und M. WOLFF: *Analysis of Verbal and Nonverbal Acoustic Signals with the Dresden UASR System*. In: ESPOSITO, A., M. FAUNDEZ-ZANUY, E. KELLER und M. MARINARO (Hrsg.): *Verbal and Nonverbal Communication Behaviours. COST Action 2102 International Workshop, Vietri sul Mare*, Bd. 4775 d. Reihe *Lecture Notes in Artificial Intelligence*, S. 200–218. Springer-Verlag, 2007.
- [15] PAULUS, J.: *Signal Processing Methods for Drum Transcription and Music Structure Analysis*. Doktorarbeit, Tampere University of Technology, 2009.
- [16] PAULUS, J. und A. KLAPURI: *Drum Sound Detection in Polyphonic Music with Hidden Markov Models*. *EURASIP Journal on Advances in Signal Processing*, 2009.
- [17] PAULUS, J. K. und A. P. KLAPURI: *Conventional and Periodic N-Grams in the Transcription of Drum Sequences*. In: *Inproceedings of 2003 International Conference on Multimedia and Expo*, Baltimore, USA, 2003.
- [18] UHLE, C., C. DITTMAR und T. SPORER: *Extraction of drum tracks from polyphonic music using independent subspace analysis*. In: *Proceedings of 4th International Symposium on Independent Component Analysis and Blind Signal Separation (ICA)*, S. 843–847, Nara, Japan, 2003.



## AUTORENVERZEICHNIS

<i>Amiri, H.</i> .....	58	<i>Neuschaefer-Rube, C.</i> .....	126,134
<i>Becker-Asano, C.</i> .....	201	<i>Petersen, C.</i> .....	89
<i>Begoli, E.</i> .....	201	<i>Pfarherr, P.</i> .....	64
<i>Beleites, T.</i> .....	15	<i>Pitsch, K.</i> .....	209
<i>Berton, A.</i> .....	64	<i>Preuß, S.</i> .....	126,134
<i>Birkholz, P.</i> .....	126,134	<i>Reichel, U. D.</i> .....	42
<i>Birth, M.</i> .....	233	<i>Reichel, S.</i> .....	64
<i>Bissiri, M. P.</i> .....	185	<i>Répás, J.</i> .....	225
<i>Blutner, F. E.</i> .....	11	<i>Ritter, D.</i> .....	97
<i>Bornitz, M.</i> .....	15	<i>Römer, R.</i> .....	24,89
<i>Burkhardt, F.</i> .....	201	<i>Rudolph, M.</i> .....	153
<i>Cao, M.</i> .....	142	<i>Schutte, M.</i> .....	126
<i>Cowie, R.</i> .....	201	<i>Skutella, L.V.</i> .....	209
<i>Denneler, A.</i> .....	50	<i>Steiner, I.</i> .....	201
<i>Eckers, C.</i> .....	134	<i>Straßner, D.</i> .....	110
<i>El Kadhi, A.</i> .....	58	<i>Strecha, G.</i> .....	58,153,161
<i>Ehrlich, U.</i> .....	64	<i>Suendermann-Oeft, D.</i> .....	32
<i>Engelbrecht, K.-P.</i> .....	50	<i>Süssenbach, L.</i> .....	209
<i>Fellbaum, K.</i> .....	240	<i>Trouvain, J.</i> .....	177
<i>Fobe, G.</i> .....	201	<i>Völkner, J.</i> .....	256
<i>Gebhard, P.</i> .....	201	<i>Wagner, P.</i> .....	209
<i>Graf, M.</i> .....	225	<i>Weber, M.</i> .....	64
<i>Hillmann, S.</i> .....	72	<i>Weiss, B.</i> .....	50
<i>Hirschfeld, D.</i> .....	153	<i>Wersényi, G.</i> .....	225
<i>Hoffmann, R.</i> .....	58,153,161,185,256	<i>Wirsching, G.</i> .....	97,104
<i>Höge, H.</i> .....	16	<i>Wolff, M.</i> .....	89,104
<i>Höpfner, D.</i> .....	240	<i>Yangmia, C.</i> .....	50
<i>Huber, M.</i> .....	110	<i>Zahnert, T.</i> .....	15
<i>Hübner, S.</i> .....	256	<i>Ziegenhals, G.</i> .....	248
<i>Hussain, Z.</i> .....	216	<i>Zoglauer, T.</i> .....	15,89
<i>Jäckel, R.</i> .....	153,161		
<i>Jokisch, O.</i> .....	193		
<i>Kazemzadeh, A.</i> .....	201		
<i>Kisler, T.</i> .....	42		
<i>Kleiser, N.</i> .....	169		
<i>Klimczak, P.</i> .....	80,89		
<i>Kompe, R.</i> .....	153		
<i>Kraljevski, I.</i> .....	153,185		
<i>Kröger, B. J.</i> .....	142,148,161,169		
<i>Kukla, H.</i> .....	169		
<i>Kurnot, F.</i> .....	153		
<i>Lange, P.</i> .....	32		
<i>Langenberg, T.</i> .....	193		
<i>Lindemann, J.</i> .....	89,118		
<i>Lorenz, R.</i> .....	110		
<i>Möbius, B.</i> .....	177		
<i>Neudert, M.</i> .....	15		