

# Systematische Merkmalsbewertung in komplexen Ultraschallsignalen mit Lernmaschinen

Matthias O. Franz · Yossi Yovel  
Mariana Laura Melcón · Peter Stilz  
Hans-Ulrich Schnitzler

## Maschinelles Lernen als naturwissenschaftliche Methode: wie Lernmaschinen zum Verständnis der Ultraschallverarbeitung bei Fledermäusen beitragen

### Einleitung

Das Sonarsystem der Fledermäuse ermöglicht Wahrnehmungsleistungen, die in ihrer Komplexität weit über die wohlbekannte

Echoortung von Beute oder Hindernissen hinausgehen. Als herausragende Beispiele sind hier die Erkennung bestimmter Vegetationsformen anhand ihrer Ultraschallsignaturen und das Herausfiltern des Echos eines winzigen Beutetieres aus einem verwirrenden Hintergrund von Blättern und Zweigen zu nennen. Ähnlich komplex ist die Fähigkeit der Fledermäuse, individuelle Artgenossen nur anhand ihrer Echoortungssignale zu erkennen, obwohl diese hochgradig stereotypisiert sind und keinem kommunikativen Zweck dienen. Dabei ist nicht zu vergessen, dass diese erstaunlichen Leistungen bei völliger Dunkelheit erbracht werden (Abb. 1).

Obwohl diese Verhaltensleistungen in der Fachliteratur gut beschrieben sind (eine Übersicht zur Fachliteratur findet sich in [7]), weiß man bis heute vergleichsweise wenig darüber, wie Fledermäuse diese komplexen Ultraschallsignale auswerten und welche Merkmale sie dabei benutzen. Einer der Gründe dafür ist sicherlich, dass dem menschlichen Betrachter – im Gegensatz zur visuellen Wahrnehmung – keine offensichtliche Anschauung aus seiner eigenen Sinneswelt zur Verfügung steht. Es bleibt hier nur die Analyse der Ultraschallechos mit verschiedenen Methoden aus der Signalverarbeitung und der Statistik. Häufig wird dabei so verfahren, dass der Untersuchende selbst nach auffälligen oder



**Abb. 1** Bei der Jagd müssen Fledermäuse die Ultraschallechos der umgebenden Vegetation als Hindernis interpretieren und gleichzeitig von den Echos ihrer Beute trennen. Dabei dürfen sich die Echoortungssysteme verschiedener Artgenossen nicht gegenseitig stören (Foto: D. Nill)

plausiblen Merkmalen in den Echos sucht und diese dann anhand von Verhaltensexperimenten über-

DOI 10.1007/s00287-011-0557-4  
© Springer-Verlag 2011

Matthias O. Franz  
Institut für optische Systeme, Hochschule Konstanz  
für Technik, Wirtschaft und Gestaltung,  
Brauneggerstr. 55, 78462 Konstanz, Deutschland  
E-Mail: mfranz@htwg-konstanz.de

Yossi Yovel · Mariana Laura Melcón · Peter Stilz  
Hans-Ulrich Schnitzler  
Lehrstuhl für Tierphysiologie, Institut für Zoologie,  
Universität Tübingen,  
Auf der Morgenstelle 28, 72076 Tübingen, Deutschland

Yossi Yovel  
Department of Zoology, Faculty of Life Science,  
Tel-Aviv University, Tel-Aviv 69978, Israel

Mariana Laura Melcón  
Marine Physical Laboratory, Scripps Institution of  
Oceanography, University of California San Diego,  
9500 Gilman Dr., La Jolla, CA 92093-0205, USA

## Zusammenfassung

Fledermäuse können anhand von Ultraschallsignalen sehr komplexe Unterscheidungen treffen. Bisher ist es immer noch unklar, welche Signalmerkmale die Grundlage für die erstaunlichen Verhaltensleistungen dieser Tiere bilden. Anhand zweier Beispiele, der Bestimmung der Artzugehörigkeit einer Pflanze aus ihrem Ultraschallecho und der Erkennung eines Fledermaus-Individuums aus seinem Echoortungssignal, wird hier gezeigt, dass moderne Methoden des maschinellen Lernens zu neuartigen und z. T. überraschenden Erkenntnissen in dieser Frage führen können. Die eingesetzten Lernmaschinen überprüfen dabei systematisch eine große Anzahl möglicher Merkmale und bewerten sie anhand ihrer Wichtigkeit für die Unterscheidungsaufgabe.

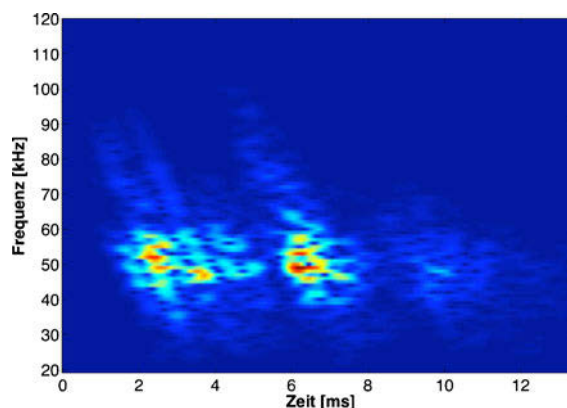
prüft. Dieses Vorgehen hat einen entscheidenden Nachteil: Die Auswahl der Merkmale geschieht nach den Kriterien eines menschlichen Beobachters, was die Gefahr in sich birgt, dass die entscheidenden Merkmale übersehen werden.

Eine Alternative zu diesem Verfahren bieten neuere Ansätze aus dem Feld des maschinellen Lernens, das sich sowohl der Methodik der Neuroinformatik als auch der Statistik bedient. Im Zusammenhang mit der Frage nach der Merkmalsselektion in komplexen Ultraschallsignalen sind hier v. a. Klassifikationsverfahren von Interesse, die eine große Zahl von möglichen Merkmalen systematisch anhand statistischer Kriterien überprüfen und ihre Wichtigkeit für die jeweilige Klassifikationsaufgabe bewerten, ohne dass ein menschlicher Beobachter hierbei eingreifen muss. In den nachstehend beschriebenen Untersuchungen wird ein prototypischer Vertreter dieser Verfahren eingesetzt, die *Supportvektormaschine* (SVM, Überblick in [6]). SVMs erfreuen sich großer Beliebtheit in technischen Anwendungen, da sie relativ einfach einzusetzen und theoretisch gut verstanden sind. Andere Verfahren des maschinellen Lernens wie z. B. *Boosting* [1] oder Gauß'sche Prozesse [5] wären für die genannte Fragestellung ebenso geeignet, wurden aber aufgrund des größeren Aufwandes bei der Berechnung des Klassifikators nicht weiter untersucht.

Im Folgenden werden SVMs detaillierter diskutiert, besonders in Hinblick auf die Frage der Merkmalsselektion, bevor wir ihre Anwendung auf zwei Klassen von komplexen Ultraschallsignalen beschreiben: Echos von Bäumen und Hecken und Echoortungslaute von einzelnen Fledermaus-Individuen, die es jeweils zu unterscheiden gilt. Abschließend werden wir nochmals in einem allgemeineren Kontext beleuchten, inwiefern der Einsatz von Lernmaschinen eine Erweiterung der naturwissenschaftlichen Methodik bedeuten kann.

## Supportvektormaschinen

Bei statistischen Klassifikationsverfahren werden die zu klassifizierenden Objekte durch eine Anzahl von Messgrößen oder *Merkmalen* charakterisiert. Eine spezifische Instanz einer Objektklasse ist dabei durch einen Satz von Messwerten gekennzeichnet, der in einem *Merkmalsvektor* zusammengefasst wird. Die für unsere Fragestellung wichtigen „Objekte“ sind Ultraschallsignale einer bestimmten Dauer, die durch eine möglichst große Anzahl von Kennwerten umfassend beschrieben werden sollen. In den nachfolgend beschriebenen Studien wurde dazu (u. a.) das Spektrogramm der als Zeitreihen über Mikrofone aufgenommenen Ultraschallechos und Ortungssignale berechnet (Abb. 2). Hierbei werden die Zeitreihen zunächst



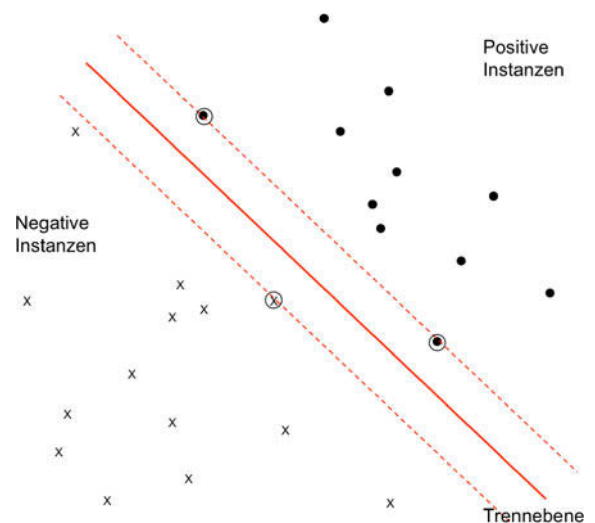
**Abb. 2** Spektrogramm des Ultraschallechos eines Apfelbaumes. Dargestellt ist die Signalamplitude zu verschiedenen Zeitpunkten, zerlegt nach Frequenzbändern (Amplitude steigt von dunkel nach hell). Die komplexe Struktur des Signals wird durch die Abfolge von Blättern und Ästen des Baumes bestimmt. Sie variiert stark von Baum zu Baum und mit dem Beobachtungswinkel. Das gezeigte Spektrogramm hat 95 Frequenzbänder in 90 Zeitfenstern und ist somit 8550-dimensional

## Abstract

Bats are capable of taking very complex decisions based on ultrasound signals. So far, it remained elusive which features allow for the astonishing behavioural abilities of these animals. We show that machine learning methodology leads to novel and sometimes surprising insights into this question using two examples: the determination of the plant species from its ultrasound echo and the recognition of a conspecific bat individuum from its echolocation call. The learning machines are used to systematically examine a large number of candidate features and evaluate them in terms of their relevance for the discrimination task.

in überlappende Fenster eingeteilt, innerhalb derer man dann eine lokale Fourieranalyse durchführt. Die einzelnen Merkmale stellen in diesem Fall eine Messung der Signalamplitude zu einem bestimmten Zeitpunkt und innerhalb eines bestimmten Frequenzbandes dar. Die Anzahl der auf diese Weise erhaltenen Merkmale und damit die Dimensionalität des zugehörigen *Merkmalsraumes* ist sehr groß (in unserem Fall bis zu 8550 Zeit-Frequenz-Kombinationen), sodass vor Anwendung eines Klassifikationsverfahrens die Dimensionalität des Merkmalsraumes reduziert werden musste. Dies geschah durch eine Hauptkomponentenanalyse, bei der die Merkmalskombinationen mit dem größten Anteil an der Signalvarianz identifiziert werden (s. z. B. [4]). Dabei zeigte sich, dass ein daraus konstruierter 240–300-dimensionaler Merkmalsraum zur Repräsentation der Spektrogramme ausreichte.


Die eingesetzten SVMs gehören zu den linearen Klassifikationsverfahren. Die zu klassifizierenden Objekte werden über ihre Merkmalsvektoren als Datenpunkte im Merkmalsraum dargestellt. Die Klassifikationsaufgabe besteht nun darin, die den Klassen entsprechenden Punktwolken möglichst sauber durch eine Ebene im Merkmalsraum zu trennen. Die verschiedenen linearen Klassifikationsverfahren unterscheiden sich darin, wie die Trennebene gefunden wird. Im Falle der SVM wird die Trennebene so gewählt, dass die Datenpunkte einen möglichst breiten Korridor um die Ebene bilden, d. h. die *Trennbreite* wird maximiert (Abb. 3).



**Abb. 3** Schematische Darstellung der Klassifikation mit Supportvektormaschinen. Die zu klassifizierenden Objekte sind durch ihre (hier zweidimensionalen) Merkmalsvektoren repräsentiert. Die Trennebene des Klassifikators wird so gewählt, dass sie die Vertreter beider Klassen (positive und negative Instanzen – Kreise und Kreuze) korrekt trennt und dabei die Trennbreite maximiert. Die Lage der Trennebene wird nur durch wenige Datenpunkte bestimmt, den Supportvektoren (markiert durch Ringe)

Dieses Auswahlkriterium hat tiefgreifende Folgen für das Verhalten des resultierenden Klassifikators: Man kann zeigen, dass eine Ebene mit maximaler Trennbreite mit hoher Wahrscheinlichkeit auch bisher noch nicht gesehene Datenpunkte korrekt klassifiziert (z. B. [2]). Dieses Resultat gilt erstaunlicherweise unabhängig von der Dimensionalität der Datenpunkte. Damit sind SVMs besonders für die hochdimensionalen Merkmalsräume unserer Fragestellung geeignet. Hinzu kommen numerisch vorteilhafte Eigenschaften des zugrundeliegenden Optimierungsproblems: Es existieren nur globale Maxima für die Trennbreite, sodass sehr effektive Optimierungsalgorithmen eingesetzt werden können.

In vielen Fällen ist die perfekte lineare Trennung der zu den beiden Klassen gehörenden Datenwolken unmöglich. Man muss hier eine gewisse Anzahl von Fehlklassifikationen zulassen, was wiederum einen Kompromiss zwischen zwei widerstreitenden Zielen erfordert: Einerseits soll die Trennbreite möglichst groß sein, andererseits führt eine größere Trennbreite auch zu häufigeren Fehlklassifikationen. Die jeweilige Gewichtung beider Teilziele wird



**Abb. 4 Gewichtung der einzelnen Frequenz-Zeit-Kombinationen eines trainierten SVM-Klassifikators für die Unterscheidung zwischen Apfelbäumen und Buchen. Ein relativ kleiner Ausschnitt des Spektrogramms genügt zur Klassifikation des Echos**

in einem aufwändigen Verfahren berechnet: der *Kreuzvalidierung*. Dabei werden die Trainingsdaten in  $n$  gleich große Blöcke aufgeteilt. Man trainiert den Klassifikator für eine gegebene Gewichtung auf  $n - 1$  Blöcken und testet ihn auf dem verbleibenden Block. Dies wird für alle Permutationen der Blockreihenfolge wiederholt und daraus die gemittelte Klassifikationsleistung berechnet. Wendet man diese Prozedur auf verschiedene Gewichtungen an, lässt sich so der optimale Gewichtungsfaktor zwischen Trennbreite und Fehlklassifikationen finden.

Was ist nun der versprochene Vorteil dieses Klassifikationsverfahrens im Vergleich zum Test einzelner Merkmale? Augenfällig ist natürlich die große Anzahl parallel getesteter Merkmale. Durch das zweistufige Verfahren werden bis zu 8550 verschiedene Kombinationen von Frequenzen und Zeitpunkten systematisch in Bezug auf ihre Unterscheidungsfähigkeit getestet. Der resultierende lineare Klassifikator weist jedem einzelnen Merkmal eine Gewichtung zu, die seine Wichtigkeit für den Klassifikationsprozess angibt (Abb. 4). Damit entfällt die sonst notwendige Vorauswahl von geeigneten Merkmalskombinationen durch den Untersuchenden zur experimentellen Überprüfung. Als Kriterium der Merkmalsselektion bzw. -bewertung dient dabei die Trennbreite auf den vorhandenen Daten, also ein rein statistisches Kriterium, das sich nur aus der Forderung nach einer möglichst guten Klassifikationsleistung ergibt,

nicht aus Plausibilitätserwägungen oder Vorlieben des Experimentators.

### Bestimmung der Pflanzenart aus Ultraschallechos

In der ersten Studie [7] wurde auf eine umfangreiche Datenbank von Vegetationsechos zurückgegriffen, die am Lehrstuhl Tierphysiologie der Universität Tübingen aufgenommen wurde. Das biomimetische Aufnahmesystem erzeugte zu diesem Zweck einen Ultraschallimpuls mit einem Spektrogramm, das in seiner Zusammensetzung sehr ähnlich zu dem realer Fledermäuse ist. Das Echo der Pflanze wurde mit zwei Mikrofonen aufgezeichnet, entsprechend den beiden Ohren der Fledermaus. Die Datenbank enthält jeweils 6250 Echos von 5 Pflanzenarten (je 50 Vertreter von Mais, Apfelbaum, Buche, Fichte, Schlehe), aufgenommen unter 25 standardisierten Winkeln. Nach einigen Vorverarbeitungsschritten wurden aus den Echos die zugehörigen Spektrogramme mit den besagten 8550 Einträgen berechnet. Die Spektrogramme wiesen eine schwer interpretierbare, komplexe Struktur auf, sodass für diese Art von Merkmalen tatsächlich nur ein statistischer Klassifikationsansatz in der Art der SVM in Frage kam.

Die SVMs wurden entweder für die Unterscheidung zweier Pflanzenarten (*one vs. one*) oder einer Pflanzenart vom Rest (*one vs. all*) nach dem oben beschriebenen Verfahren trainiert. Die Auswertung der Klassifikationsleistung erfolgte im bereits erwähnten Verfahren der Kreuzvalidierung, um mögliche Artefakte der zufälligen Aufteilung der Daten in Trainings- und Testmenge zu reduzieren.<sup>1</sup> Die trainierten Klassifikatoren waren erstaunlich leistungsfähig: Für fast alle Paarungen lag die Leistung konsistent bei einem Anteil von 95–99 % korrekten Klassifikationsentscheidungen (mit einigen Ausnahmen bei 81–93 %). Dieses Ergebnis übertrifft um so mehr, als dass dieselbe Klassifikationsaufgabe im visuellen Bereich schwieriger zu realisieren wäre und eine erheblich größere Menge an Trainingsdaten erfordern würde. Man kann daraus schließen, dass die scheinbar schwierige Bestimmung der Artzugehörigkeit einer Pflanze aus einem einzigen Ultraschallecho für die Fledermaus keine besondere Schwierigkeit darstellen sollte.


<sup>1</sup> Es finden hier also zwei verschachtelte Kreuzvalidierungen statt: einerseits innerhalb der Trainingsdaten zum Auffinden der optimalen Gewichtung zwischen Trennbreite und Klassifikationsfehler, andererseits auf *allen* Daten zur Bestimmung der Leistung des trainierten Klassifikators.

Betrachtet man die Gewichtung, die die trainierten SVMs den einzelnen Zeit-Frequenz-Kombinationen des Spektrogramms zuweisen, so zeigt sich, dass bereits einige wenige Spektrogrammeinträge ausreichen, um die Artzugehörigkeit der Pflanze mit großer Sicherheit zu bestimmen (Abb. 4). Die Position der wichtigsten Spektrogrammeinträge ändert sich jedoch je nach Art der Klassifikationsaufgabe. Interessanterweise decken sich die gefundenen Zeit-Frequenz-Kombinationen recht gut mit dem, was über die Hörphysiologie der Fledermaus bekannt ist.

Warum ist die Bestimmung der Artzugehörigkeit eines Pflanzenechos nun so einfach? In einer weiteren Untersuchung [9] konnten wir zeigen, dass das Auftreten bestimmter Frequenzen im Ultraschallecho mit besonders häufigen Abständen zwischen den Reflektoren assoziiert ist. Bei Pflanzen sind die hauptsächlichen Reflektoren die Blätter. Jede Pflanzenart hat für sie typische Abstände zwischen den Blättern oder Nadeln, die zu entsprechenden Frequenzen im Spektrogramm führen. Darüber hinaus wird die Häufigkeit der Blätter durch die Struktur der Zweige und Äste moduliert, was wiederum im Spektrogramm zu charakteristischen zeitlichen Abständen der Teilechos führt. Die SVM identifiziert genau diese spezifischen Kombinationen von Frequenzen und Zeitpunkten, anhand derer sich die Echos zweier verschiedener Pflanzenarten besonders gut unterscheiden lassen.

## Erkennung individueller Artgenossen aus ihren Echoortungslauten

Im Gegensatz zu Vegetationsechos haben die einzelnen Echoortungslaute der Fledermäuse eine sehr einfache, stereotypisierte Struktur (Abb. 5). Individuelle Unterschiede der Spektrogramme verschiedener Artgenossen fallen dabei nicht ins Auge. Hinzu kommt eine besondere Schwierigkeit: Fledermäuse variieren ihre Ortungslaute *kontextabhängig*, d. h., sie passen diese den momentanen Abständen der Hindernisse und etwaigen Beutetieren an. Dies führt zu einer sehr großen Variabilität in den Echoortungslauten der einzelnen Fledermäuse, was ihre Zuordnung zu bestimmten Individuen erheblich erschwert. Dennoch scheint die Erkennung einzelner Artgenossen anhand ihrer Ortungssignale eine Rolle im Fledermausverhalten zu spielen, v. a. bei der Jagd in Gruppen. Auch hier war es bisher



**Abb. 5** Spektrogramm eines Echoortungslautes des großen Mausohrs (*Myotis myotis*). Die einfache Frequenz-Zeit-Struktur ist stark stereotypisiert und variiert nur wenig von Individuum zu Individuum, aber dafür umso stärker von Situation zu Situation

unklar, welche Merkmale der Ultraschallsignale dabei eine Rolle spielen könnten.

Bei der Untersuchung dieser Frage muss zuerst zweifelsfrei festgestellt werden, ob Fledermäuse zur individuellen Erkennung aus Ortungssignalen überhaupt fähig sind, denn die Rolle dieser Verhaltensleistung bei der Jagd in Gruppen ist bisher rein hypothetisch. Dazu wurde ein Experiment durchgeführt, bei dem einer Fledermaus aus zwei Lautsprechern die Ortungslaute zweier Artgenossen vorgespielt wurden. Bewegte sich die Fledermaus in Richtung eines bestimmten Artgenossen, wurde sie mit einem Mehlwurm belohnt, ansonsten nicht. Diese Prozedur wurde in einer Trainingsphase von mehreren Wochen wiederholt, bis die Fledermaus eine zufriedenstellende Erkennungsleistung zeigte. In der anschließenden Testphase wurden Ortungslaute der gleichen Fledermaus gespielt, die die getesteten Fledermäuse aber während ihres Trainings nie gehört hatten. Aufgrund der großen Variabilität der Echoortungslaute ist die Erkennung des richtigen Artgenossen eine schwierige Aufgabe, die die Fledermaus jedoch souverän meisterten [8].

Nachdem die grundsätzliche Fähigkeit bei den Fledermäusen gezeigt war, konnten wir nun – ähnlich wie bei den Vegetationsechos – mithilfe von Lernmaschinen untersuchen, welche Merkmale bei der Erkennung individueller Artgenossen eine Rolle spielen könnten. Die Datenbasis bildeten die gleichen aufgenommenen Ortungssignale, die auch in den Verhaltensexperimenten zum Einsatz kamen. Damit wurden Tier und Maschine vor

die gleiche Klassifikationsaufgabe gestellt. Ähnlich wie bei den Vegetationsechos wurden nach einigen Vorverarbeitungsschritten die Spektrogramme der Ortungslaute berechnet, dieses Mal mit einer niedrigeren Auflösung (4200 statt 8550 Zeit-Frequenz-Kombinationen). Die damit trainierten SVMs erreichten eine sehr hohe Klassifikationsleistung, die sogar die der Fledermäuse übertraf. Interessanterweise zeigte sich, dass beinahe die gleiche Leistung auch mit einem reduzierten Spektrogramm erzielt werden konnte, bei dem über alle Zeitpunkte gemittelt wurde und somit nur noch die Frequenzinformation vorhanden war. Dies lässt sich dahingehend interpretieren, dass die für die Zuordnung zu einem Individuum entscheidenden Merkmale eines Echoortungslautes durch die Filtereigenschaften des Stimmapparates bestimmt werden, die wiederum durch bestimmte individuelle Resonanzen im Vokaltrakt (sogenannte *Formanten*) zustandekommen. Diese spielen die Hauptrolle bei der Erkennung menschlicher und tierischer Stimmen. Somit lässt sich sagen, dass sich die in Gruppen aktiven Fledermäuse mit hoher Wahrscheinlichkeit anhand ihrer Stimme wiedererkennen können, die sich unseren Ergebnissen zufolge auch hinreichend stark auf die Frequenzzusammensetzung ihrer Echoortungslaute auswirkt.

## Diskussion

Es bleibt zu hoffen, dass die beiden beschriebenen Untersuchungen die Hauptaussage des vorliegenden Texts deutlich machen: Durch den Einsatz des maschinellen Lernens wird der Forschung ein neues Instrument an die Hand gegeben, das die simultane und systematische Untersuchung einer großen Anzahl von Hypothesen erlaubt. Die Hypothesen (in unserem Fall bestimmte Merkmale der Ultraschallsignale) werden nur nach ihrer statistischen Vorhersagekraft beurteilt, nicht nach ihrer – wie auch immer gearteten – Plausibilität. Damit lässt sich ein relativ vorurteilsfreier Blick auf den Hypothesenraum gewinnen, der oftmals

überraschende Erklärungen für ein Phänomen oder eine Verhaltensleistung liefert, die im Vorfeld nicht offensichtlich sind oder womöglich übersehen wurden.

Natürlich stellt die hier verwendete Kombination aus Spektrogrammen und linearen Klassifikatoren ebenfalls eine Einschränkung des möglichen Merkmalsraumes dar. Denkbar wären ja auch nichtlineare Merkmale der Ultraschallsignale wie z. B. Varianz oder Kurtosis der Zeitreihe, die in vergleichbaren Untersuchungen getestet wurden. Im Prinzip kann eine SVM sehr leicht auf solche nichtlinearen Merkmale erweitert werden, indem man die Daten zunächst nichtlinear transformiert, bevor man die Trennebene berechnet. Dennoch stellt die Wahl einer bestimmten nichtlinearen Transformation auch hier eine Einschränkung der möglichen nichtlinearen Merkmale dar. Allgemein lässt sich zeigen, dass man diese Art von experimenteller „Willkür“ nie ganz loswerden kann (eine Konsequenz des „*no free lunch*“-Theorems; s. z. B. [3]). Trotzdem stellt der erheblich größere Merkmalsraum, der in den beiden oben beschriebenen Ansätzen durchsucht wurde, eine systematische Erweiterung der traditionellen Methodik dar, die bisher bei der Merkmalssuche allein auf die Intuition des Experimentators angewiesen war.

## Literatur

1. Bishop CM (2006) Pattern recognition and machine learning. Springer, Heidelberg
2. Cristianini N, Shawe-Taylor J (1999) An introduction to support vector machines. Cambridge University Press, Cambridge
3. Duda RO, Hart PE, Stork DG (2001) Pattern Classification. Wiley, New York
4. Haykin S (1999) Neural Networks. Prentice Hall, Upper Saddle River, NJ
5. Rasmussen CE, Williams CKI (2006) Gaussian processes for machine learning. MIT Press, Cambridge, MA
6. Schölkopf B, Smola AJ (2002) Learning with kernels. MIT Press, Cambridge, MA
7. Yovel Y, Franz MO, Stilz P, Schnitzler H-U (2008) Plant classification from bat-like echolocation signals. PLoS Comput Biol 4(3):e1000032, doi:10.1371/journal.pcbi.1000032
8. Yovel Y, Melcón ML, Franz MO, Denzinger A, Schnitzler H-U (2009) The voice of bats: how greater mouse-eared bats recognize individuals based on their echolocation calls. PLoS Comput Biol 5(6):e1000400, doi:10.1371/journal.pcbi.1000400
9. Yovel Y, Stilz P, Franz MO, Boonman A, Schnitzler H-U (2009) What a plant sounds like: the statistics of vegetation echoes as received by echolocating bats. PLoS Comput Biol 5(7):e1000429, doi:10.1371/journal.pcbi.1000429