

Fahrzeugtyperkennung mit neuronalem Netz und lernender Vektorquantisierung - ein Vergleich

JÜRGEN ALTMANN*, SERGEY LINEV*, PETER VYKOUPIĽ*

* Bochumer Verifikationsprojekt, Institut für Experimentalphysik III, Ruhr-Universität Bochum, 44780 Bochum
+ 47447 Moers

1. Allgemeines Ziel

Das Bochumer Verifikationsprojekt (BVP) untersucht mittels angewandt-physikalischer Forschung, ob automatische Sensorsysteme für die kooperative Verifikation von Abrüstungs- und Friedensabkommen geeignet sind. Für passiven, tageszeit- und wetterunabhängigen Nachweis über mittlere Entfernungen benutzen wir v.a. Schall und Bodenvibration. Angestrebt werden Sensorstationen, die aufgenommene Signale weitgehend autonom verarbeiten und bei Vertragsverletzung bzw. unklarem Ereignis einen Alarm an eine Zentrale senden. Dabei ist eine Aussage über den erkannten Fahrzeugtyp hilfreich, die aus dem Motorschall gewonnen werden soll.

2. Messungen

Mittels einer eigens entwickelten Sensorstation - 4 Kanäle, spezieller ADC hoher Dynamik, digitaler Signalprozessor, Pentium 233 MHz [1] – wurden zwischen 12. und 20. Okt. 2000 Durchfahrten von 5 Ketten- und 5 Radfahrzeugen auf dem Gelände der Wehrtechnischen Dienststelle 91 in Meppen gemessen.[2] Die Fahrzeuge fuhrten auf einer Betonstraße und drei parallelen Sandstrecken (+/-200 m) mit 7 Geschwindigkeiten in beiden Richtungen zwischen zwei Stationen hindurch; deren Abstand war 101 m (Tab. 1). An jeder Station wurden ein Mikrofon- und drei Geofonsignale (3D) mit Abstraten von 20 bzw. 5 kHz aufgenommen, über Ethernet an einen Notebook-PC übertragen und dort gespeichert (zunächst Festplatte, dann CD-ROM).

Tab. 1 Verwendete Fahrzeuge, Anzahl ausgewählter bzw. erfolgreich ausgewerteter Durchfahrten sowie benutzte Geschwindigkeiten

Kette:		Geschw./ (km/h)
Leopard 1	50/50	
Leopard 2	50/42	40
M 48	41/41	30
Jaguar	39/35	20
Wiesel	41/0	15
Rad:		
Fuchs	38/31	10
Hermelin	31/23	5
MB 1017	30/21	min.
Unimog	27/24	
VW-Bus	10/0	Stand

3. Auswertungen

3.1 Vorverarbeitung

Für jede Durchfahrt wurden die Zeitintervalle bestimmt, während derer das akustische Signal klar über dem Untergrund war. In allen Leistungsspektren (Dauer je 0,82 s) aus diesen Intervallen wurden die Linien bestimmt und die am besten passende harmonische Serie gefunden. Die damit bekannten Leistungen bei den Harmonischen der Motorgrundfrequenz wurden auf die Seriensumme normiert, sie nehmen also Werte zwischen 0 und 1 an. Bei zwei Fahrzeugen waren zu wenige Harmonische für die Serienerkennung vertreten.

Diese relativen Stärken der Harmonischen 1 bis 15 bilden Mustervektoren. Sie sind invariant in Bezug auf Zeitverschiebung, Amplitude und Grundfrequenz, damit genähert auch in Bezug auf Abstand und Dopplerverschiebung. Zur Anhebung der kleinen Komponenten (sie sind bis hinunter zu etwa 10^{-5} signifikant) wurden alle Werte mit

$$H_i' = f(H_i) = \log(10^5 H_i + 1) / \log(10^5 + 1)$$

verzerrt (unter 10^{-5} etwa linear, oberhalb etwa logarithmisch).

3.2 Typerkennung

Zur Typerkennung wurde ggf. zunächst nach Ketten- bzw. Radantrieb getrennt (das ging zu 94% richtig mittels der maximalen akustischen und seismischen Amplituden [2]). Dann wurden 1. lernende Vektorquantisierung und 2. ein neuronales Netz angewandt; verglichen wurde mit der Diskriminanzanalyse (Bayes), die vom einfachen Fall Gauß-verteilter Klassen ausgeht. I.d.R. wurden etwa 2/3 der vorhandenen Vektoren zum Lernen und 1/3 zum Testen benutzt.

Lernende Vektorquantisierung (LVQ)

Hier wird eine Klasse durch einen Satz von Kodevektoren beschrieben, die das von den Mustervektoren dieser Klasse aufgespannte Volumen etwa abdecken.[3] Die Programme aus LVQ_Pak [4] wurden mit 10 Kodevektoren für jede der 8 Klassen verwendet, unbesetzte Komponenten wurden bei der Abstandsberechnung weggelassen.

Neuronales Netz

Hier werden die Vektorkomponenten in der Eingangsschicht auf je ein Neuron gegeben. Dann folgen eine oder mehrere Zwischenschichten und schließlich die Ausgangsschicht mit je einem Neuron pro Klasse. Die Erregungen der Neuronen einer Schicht werden – mit Synapsengewichten multipliziert – auf die der folgenden übertragen und dort summiert.[3] Wir verwendeten ein Backpropagation-Netzwerk (Programm ARTIFIN [5]) mit 1 (Kette) bzw. 4 (Rad) Zwischenschichten aus je 17 Neuronen bei 15 Eingangs- und 8 Ausgangsneuronen. Unbesetzte Komponenten wurden mit dem Wert 0 in Lernen und Testen einbezogen.

4. Ergebnisse

In einem ersten Versuch waren bei der LVQ die fehlenden Komponenten mit dem Wert 0 einbezogen worden.[2] Dabei waren zum Lernen für jedes Fahrzeug 7 Vektoren zufällig ausgewählt und die Erkennung war mit weiteren 3 Vektoren geprüft worden. Über das gesamte ausgewählte Intervall ergaben sich die Anteile korrekter Erkennung von 81-98% für Ketten- und 46-62% für Radfahrzeuge. Neue Rechnungen der Diskriminanzanalyse ergaben nun – bei je weggelassenen fehlenden Komponenten – sogar höhere Werte (Tab. 2). Daher wurden jetzt auch bei der LVQ die fehlenden Komponenten ausgelassen.

Für den Erkennungsvergleich wurden Ketten- und Radfahrzeuge getrennt behandelt. Tab. 3 zeigt die Ergebnisse, wenn alle vorhandenen Mustervektoren benutzt wurden.

LVQ und neuronales Netz liegen beide deutlich über der Diskriminanzanalyse; der Unterschied ist besonders markant bei den Radfahrzeugen.

Tab. 2 Frühere LVQ-Erkennung, fehlende Komponenten als Wert 0 einbezogen, zufällige Auswahl (7+3 Vektoren pro Fahrzeug) aus den verarbeiteten Zeitabschnitten, alle Fahrzeuge zusammen (Kette 3.080, Rad 1.610, zusammen 4.690 Vektoren). Vergleich mit Diskriminanzanalyse (Bayes, fehlende Komponenten weggelassen)

	Number	LVQ including zeroes Accuracy	Discrimin. Anal. without zeroes Accuracy
Leopard 1	273	97.8%	96.3%
Leopard 2	228	83.3%	79.0%
M 48	237	92.0%	89.9%
Jaguar	186	81.2%	86.6%
Fuchs	171	62.0%	73.7%
Hermelin	90	51.1%	75.6%
MB 1017	111	47.8%	49.6%
Unimog	111	46.0%	61.3%
Total:	1407	76.9%	80.6%

Interessant ist auch die Zeit, wenn die Signalstärke am höchsten ist, also kurz nach der Vorbeifahrt. Einerseits erwartet man gute Linien- und Serienerkennung, andererseits ändert sich der Abstrahlwinkel am schnellsten. Zur Beurteilung wurden für jede verarbeitete Durchfahrt 10 Vektoren unmittelbar nach dem Amplitudenmaximum verwendet (Tab. 4). Die meisten Erkennungswahrscheinlichkeiten liegen leicht höher.

Tab. 3 Vergleich Erkennung mittels LVQ, neuronalem Netz und Diskriminanzanalyse (Bayes), gesamte verarbeitete Zeitabschnitte, Ketten- und Radfahrzeuge getrennt (Kette 29.845, Rad 9.859 Vektoren; n. Netz: Test mit Stichproben). Bei LVQ und Diskriminanzanalyse wurden fehlende Komponenten weggelassen, beim neur. Netz als 0 einbezogen.

	LVQ	N.Net	Discr. Anal.
<i>Tracked vehicles</i>			
Leopard 1	98.2%	99%	97.1%
Leopard 2	96.7%	99%	91.8%
M 48	98.3%	99%	96.1%
Jaguar	95.4%	99%	95.5%
Total:	97.3%	99%	95.3%
<i>Wheeled vehicles</i>			
Fuchs	94.8%	92%	90.9%
Hermelin	74.8%	87%	74.7%
MB 1017	69.1%	87%	58.7%
Unimog	82.0%	92%	67.5%
Total:	83.5%	90%	76.8%

5. Schlussfolgerungen

Die flexibleren Methoden LVQ und neuronales Netz ergeben bessere Erkennung als Diskriminanzanalyse – ein deutliches Zeichen dafür, dass die Verteilungen der Mustervektoren zu jeder Klasse nicht gut durch Gaußverteilungen in 15 Dimensionen beschrieben werden können. Bei Vorsortierung nach Ketten- und Radfahrzeugen sind die

ersteren jedoch schon durch Diskriminanzanalyse sehr gut trennbar – die zugehörigen Mustervolumina liegen offensichtlich so weit voneinander entfernt, dass Abweichungen von der Ellipsoidform nicht schaden. Bei Radfahrzeugen gelingt die Klassifikation mit LVQ und neuronalem Netz jedoch erheblich besser, insbesondere, wenn man den ganzen Durchfahrt-Zeitraum betrachtet – um das Amplitudenmaximum herum ist der Unterschied weniger ausgeprägt. Bei Radfahrzeugen ist zu berücksichtigen, dass die Grundfrequenzerkennung häufiger misslingt als bei Kettenfahrzeugen, wohl v.a. wegen der geringeren Signalamplitude der ersteren. Bei einer Durchfahrt liegen aber immer viele Spektren vor, so dass genügend viele für die Typerkennung genutzt werden können.

Insgesamt versprechen LVQ und neuronales Netz in vielen Fällen eine sehr gute Erkennung des Motortyps. Die Anteile richtiger Klassifikation beim neuronalen Netz sind etwas höher als bei LVQ, letztere kann aber wahrscheinlich noch verbessert werden (z.B. mehr Kodevektoren).

In weiteren Untersuchungen sollte angestrebt werden, auch in den Spektren von Wiesel und VW-Transporter die Grundfrequenz automatisch zuverlässig zu finden. Zur Optimierung des später anzuwendenden Erkennungsverfahrens sollten einerseits Parameter variiert und die Grundfrequenz einbezogen werden, v.a. bei der LVQ. Andererseits sollte die Struktur der Daten genauer betrachtet werden, etwa die Winkelabhängigkeit der relativen Leistungen der Harmonischen.

Tab. 4 Vergleich Erkennung mittels LVQ, neuronalem Netz und Diskriminanzanalyse (Bayes), je 10 Vektoren unmittelbar nach dem Amplitudenmaximum, Ketten- und Radfahrzeuge getrennt (Kette 3.080, Rad 1.610 Vektoren). Bei LVQ und Diskriminanzanalyse wurden fehlende Komponenten weggelassen, beim neur. Netz als 0 einbezogen.

	LVQ	N.Net	Discr. Anal.
<i>Tracked vehicles</i>			
Leopard 1	98.5%	99%	97.8%
Leopard 2	94.3%	98%	91.2%
M 48	100.0%	99%	99.6%
Jaguar	96.8%	97%	94.6%
Total:	97.5%	98%	96.0%
<i>Wheeled vehicles</i>			
Fuchs	95.3%	92%	91.8%
Hermelin	78.8%	87%	71.7%
MB 1017	72.1%	85%	68.5%
Unimog	79.3%	91%	75.7%
Total:	83.1%	89%	78.9%

Literatur

- [1] Kell u.a. DAGA 01; B. Meffert et al. Monitoring for Verification – Sensor Station 2000 for Acoustic and Seismic Measurements of High Dynamic Range, Verification – Research Reports 11, Lenzen: Grüneberg, 2001
- [2] Altmann u.a. DAGA 01; S. Linev et al., Monitoring for Verification – Acoustic-Seismic Military-Vehicle Measurements of 2000 at Meppen, Germany, Verification – Research Reports 11, Lenzen: Grüneberg, 2001
- [3] T. Kohonen, Self-Organizing Maps, Heidelberg etc.: Springer 1995
- [4] http://www.cis.hut.fi/research/lvq_pak
- [5] <http://www.artifin.de>