

Ergänzungen zur Studienarbeit  
Adaptive bimodale Sensorfusion für  
automatische Spracherkennung und  
Lippenlesen

Im folgenden sind einige Ergebnisse aufgeführt, die auf obiger Studienarbeit aufbauen und im Rahmen einer Hiwi-Tätigkeit erarbeitet wurden.

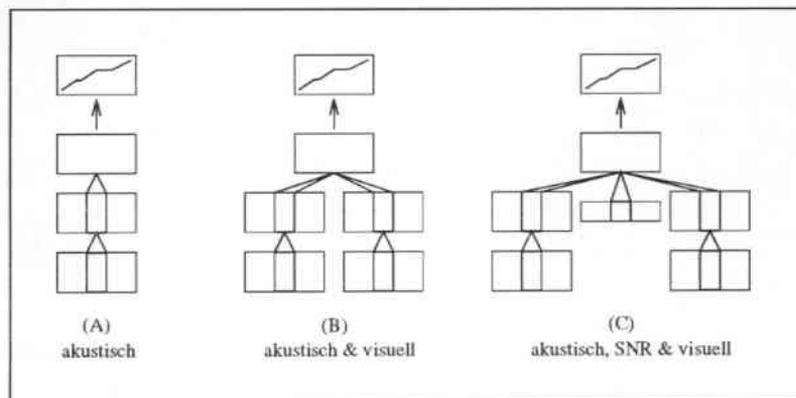
Wolfgang Hürst  
Juni 1995

## Inhalt

Nachfolgend sind einige Ergebnisse aufgelistet, die bei der Kombination von akustischen und visuellen Eingabesignalen mit verschiedenen Netzarchitekturen (Kombination auf Hidden-Ebene, siehe unten) erzielt wurden. Für eine Beschreibung des Erkenners und der genauen Problemstellung sei auf *Wolfgang Hürst: Adaptive bimodale Sensorfusion für automatische Spracherkennung und Lippenlesen, Studienarbeit, Universität Karlsruhe, Mai 1995* verwiesen.

- In **Teil I** werden die Ergebnisse verschiedener Netzarchitekturen, die jeweils mit der gleichen Trainingsdatenmenge trainiert wurden, miteinander verglichen.
- In **Teil II** sind die Ergebnisse, die mit jeweils einer Netzarchitektur und unterschiedlichen Trainingsmengen erzielt wurden, vergleichend dargestellt.

### verwendete Netzarchitekturen



- **Netz (A):** akustische Erkennung; das Netz erhält als Eingabe nur das reine Sprachsignal
- **Netz (B):** kombinierte Erkennung; das Netz erhält das akustische, sowie das „visuelle Sprachsignal“ (Bilder der entsprechenden Lippenbewegungen) als Eingabe
- **Netz (C):** kombinierte Erkennung mit zusätzlicher Information; das Netz erhält das akustische Sprachsignal, Bilder der entsprechenden Lippenbewegungen und die aus den akustischen Daten berechneten SNR-Werte (SNR = Signal-to-Noise Ratio) als Eingabe

## Datenbasis

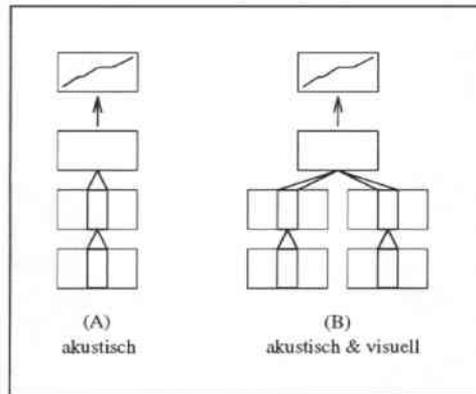
200 unter optimalen Bedingungen aufgenommene Sequenzen eines männlichen Sprechers (mum1&2), davon 170 Sequenzen für das Training und 30 Sequenzen zum Testen der jeweiligen Netze. Zu Test- und Trainingszwecken wurden diese Sequenzen durch Aufaddieren eines Störgeräusches künstlich verrauscht, so daß insgesamt folgende Test- und Trainingsdatenbasis zu Verfügung stand:

- CLEAN: unter optimalen Bedingungen aufgenommen; SNR  $\approx$  30 dB
- NOISE 1 und NOISE 2: konstantes weißes Rauschen; SNR  $\approx$  16 bzw.  $\approx$  8 dB
- INCREASE 1 und INCREASE 2: ansteigendes weißes Rauschen; SNR  $\approx$  30 bis 16 dB bzw.  $\approx$  30 bis 8 dB
- RADIO 1 und RADIO 2: laufendes Radio (Musik); SNR schwankend um  $\approx$  20 bzw.  $\approx$  17 dB
- MOTOR 1 und MOTOR 2: Motor einer aktiven Kamerasteuerung; SNR schwankend um  $\approx$  25 bzw.  $\approx$  11 dB

# I.

Ergebnisse der verschiedenen  
Netzarchitekturen bei jeweils gleicher  
Trainingsdatenmenge

## Netzarchitekturen



## Trainingsmenge

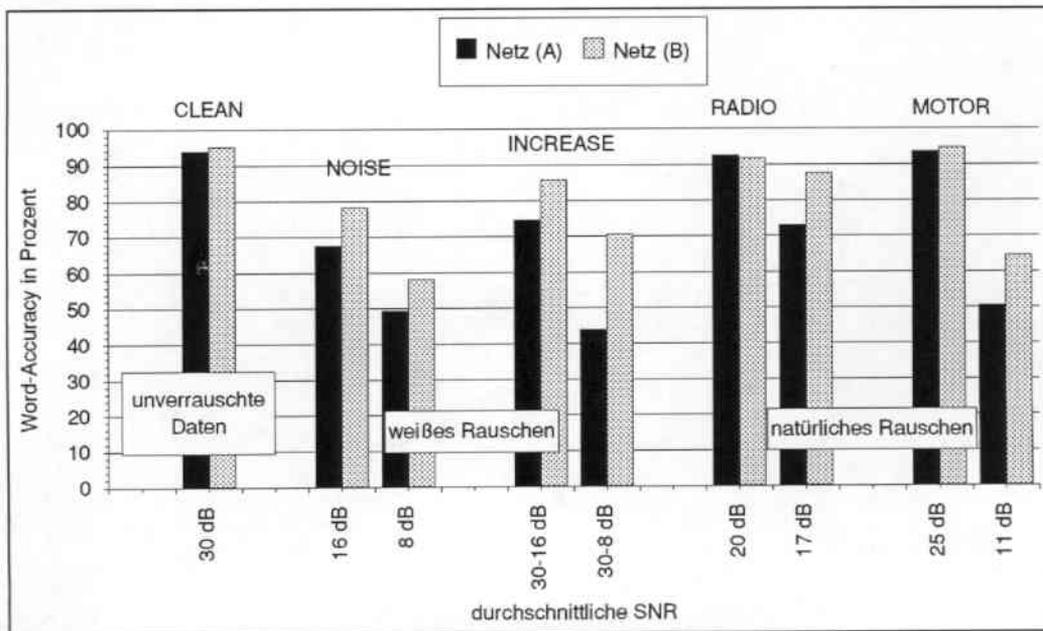
CLEAN (ca. 30 dB SNR) 170 Samples

insgesamt 170 Samples

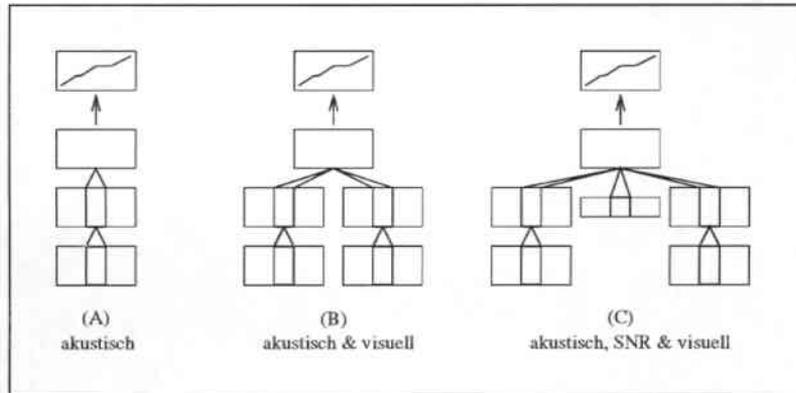
## Testergebnisse

Netzarchitektur	CLEAN	NOISE 1	NOISE 2	INCR. 1	INCR. 2	RADIO 1	RADIO 2	MOTOR 1	MOTOR 2
(A)	94.1	67.6	49.4	74.7	44.1	92.4	72.9	93.5	50.6
(B)	95.3	78.2	58.2	85.9	70.6	91.8	87.6	94.7	64.7

Erkennungsraten auf den einzelnen Testdatensets (angegeben ist jeweils die Word-Accuracy in Prozent)



## Netzarchitekturen



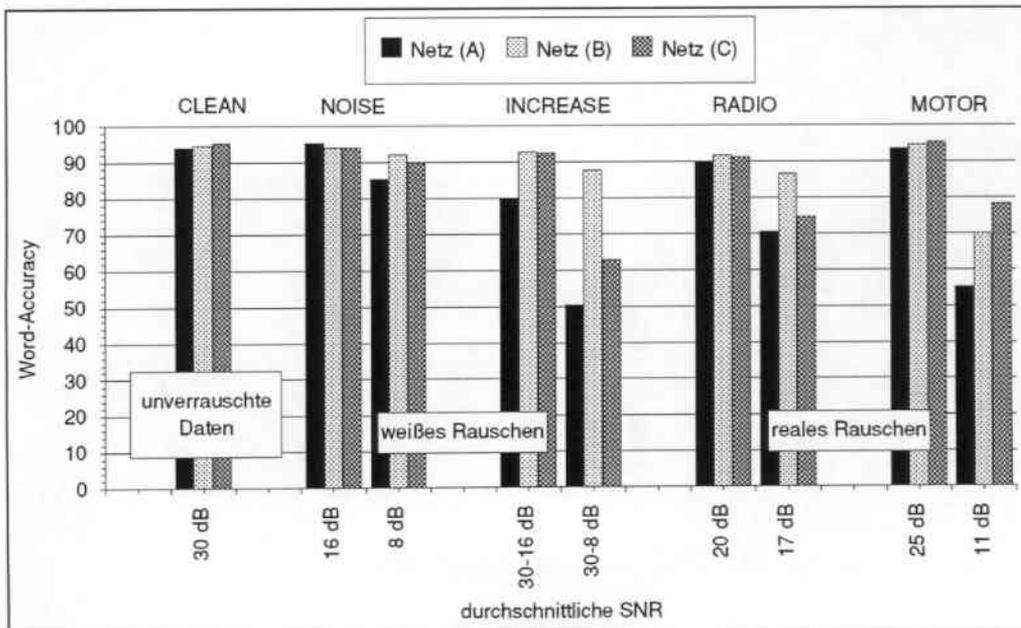
## Trainingsmenge

CLEAN (ca. 30 dB SNR)	170 Samples
NOISE 1 (ca. 16 dB SNR)	170 Samples
<b>insgesamt</b>	<b>340 Samples</b>

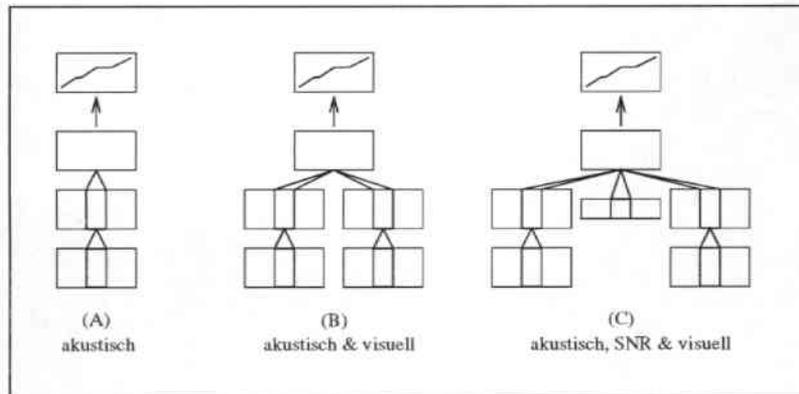
## Testergebnisse

Netzarchitektur	CLEAN	NOISE 1	NOISE 2	INCR. 1	INCR. 2	RADIO 1	RADIO 2	MOTOR 1	MOTOR 2
(A)	94.1	95.3	85.3	80.0	50.6	90.0	70.6	93.5	55.3
(B)	94.7	94.1	92.1	92.9	87.6	91.8	86.5	94.7	70.0
(C)	95.3	94.1	90.0	92.4	62.9	91.2	74.7	95.3	78.2

Erkennungsraten auf den einzelnen Testdatensets (angegeben ist jeweils die Word-Accuracy in Prozent)



## Netzarchitekturen



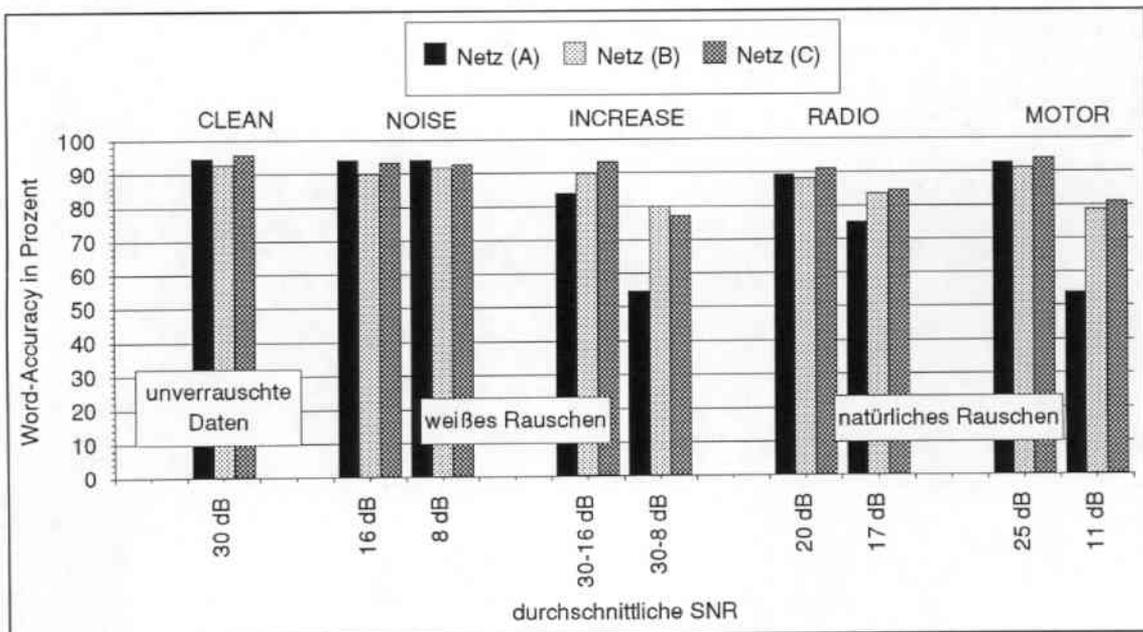
## Trainingsmenge

CLEAN (ca. 30 dB SNR)	170 Samples
NOISE 2 (ca. 8 dB SNR)	170 Samples
<hr/>	
insgesamt	340 Samples

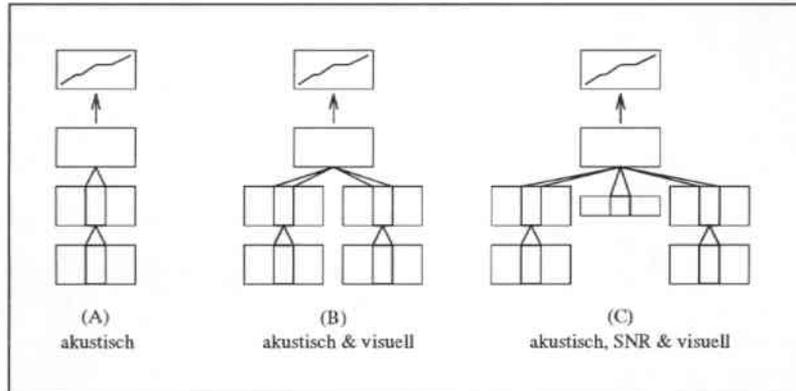
## Testergebnisse

Netzarchitektur	CLEAN	NOISE 1	NOISE 2	INCR. 1	INCR. 2	RADIO 1	RADIO 2	MOTOR 1	MOTOR 2
(A)	94.7	94.1	94.1	84.1	54.7	89.4	75.3	92.9	54.1
(B)	92.9	90.0	91.8	90.0	80.0	88.2	83.5	91.2	78.8
(C)	95.9	93.5	92.9	93.5	77.1	91.2	84.7	94.1	81.2

Erkennungsraten auf den einzelnen Testdatensets (angegeben ist jeweils die Word-Accuracy in Prozent)



## Netzarchitekturen



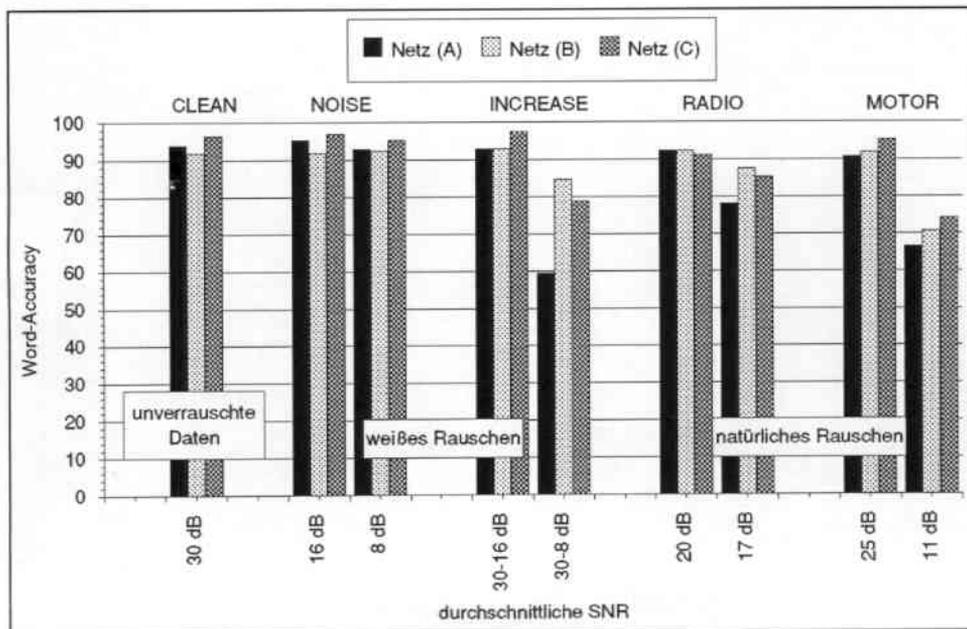
## Trainingsmenge

CLEAN (ca. 30 dB SNR)	170 Samples
NOISE 1 (ca. 16 dB SNR)	170 Samples
NOISE 2 (ca. 8 dB SNR)	170 Samples
<b>insgesamt</b>	<b>510 Samples</b>

## Testergebnisse

Netzarchitektur	CLEAN	NOISE 1	NOISE 2	INCR. 1	INCR. 2	RADIO 1	RADIO 2	MOTOR 1	MOTOR 2
(A)	94.1	95.3	92.9	92.9	59.4	92.4	78.2	90.6	66.5
(B)	91.8	91.8	92.4	92.9	84.7	92.4	87.6	91.8	70.6
(C)	96.5	97.1	95.3	97.6	78.8	91.2	85.3	95.3	74.1

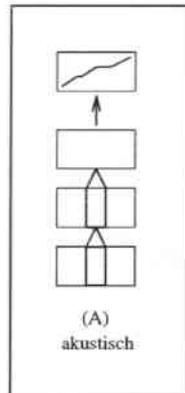
Erkennungsraten auf den einzelnen Testdatensets (angegeben ist jeweils die Word-Accuracy in Prozent)



## II.

Vergleich der Ergebnisse jeweils einer  
Netzarchitektur bei Verwendung  
unterschiedlicher Trainingsdatenmengen

## Netzarchitektur



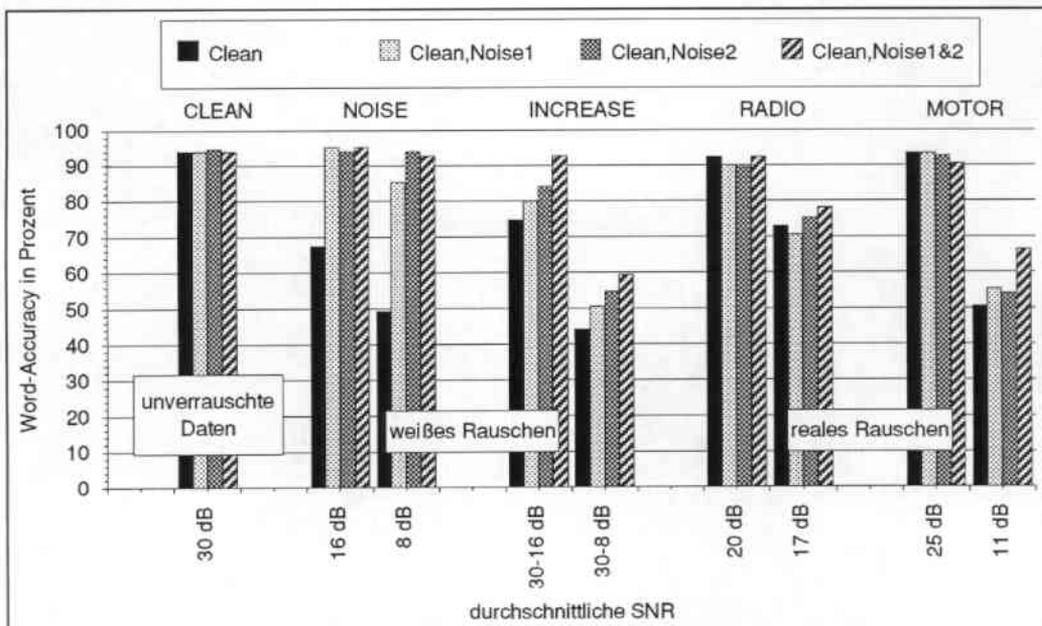
## Trainingsmengen

	Menge (1)	Menge (2)	Menge (3)	Menge (4)
CLEAN (ca. 30 dB SNR)	170 Samples	170 Samples	170 Samples	170 Samples
NOISE 1 (ca. 16 dB SNR)		170 Samples		170 Samples
NOISE 2 (ca. 8 dB SNR)			170 Samples	170 Samples
insgesamt	170 Samples	170 Samples	170 Samples	170 Samples

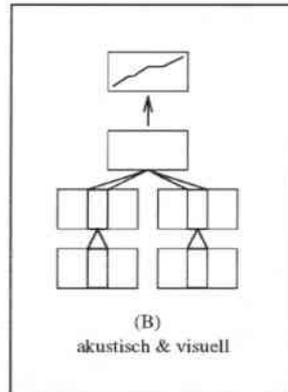
## Testergebnisse

Trainingsmenge	CLEAN	NOISE 1	NOISE 2	INCR. 1	INCR. 2	RADIO 1	RADIO 2	MOTOR 1	MOTOR 2
(1)	94.1	67.6	49.4	74.7	44.1	92.4	72.9	93.5	50.6
(2)	94.1	95.3	85.3	80.0	50.6	90.0	70.6	93.5	55.3
(3)	94.7	94.1	94.1	84.1	54.7	89.4	75.3	92.9	54.1
(4)	94.1	95.3	92.9	92.9	59.4	92.4	78.2	90.6	66.5

Erkennungsraten auf den einzelnen Testdatensets (angegeben ist jeweils die Word-Accuracy in Prozent)



## Netzarchitektur



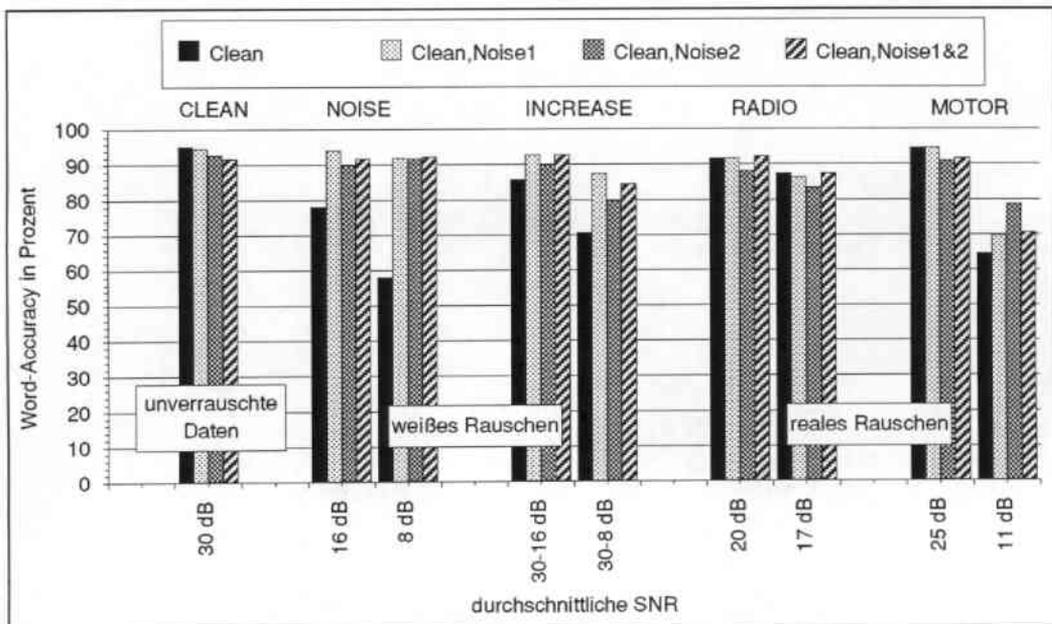
## Trainingsmengen

	Menge (1)	Menge (2)	Menge (3)	Menge (4)
CLEAN (ca. 30 dB SNR)	170 Samples	170 Samples	170 Samples	170 Samples
NOISE 1 (ca. 16 dB SNR)		170 Samples		170 Samples
NOISE 2 (ca. 8 dB SNR)			170 Samples	170 Samples
insgesamt	170 Samples	170 Samples	170 Samples	170 Samples

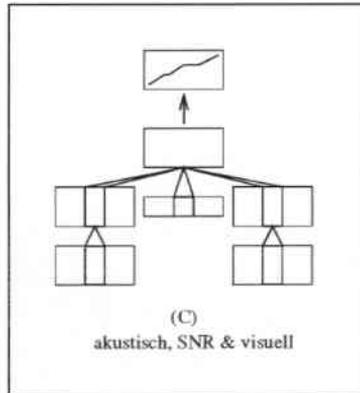
## Testergebnisse

Trainingsmenge	CLEAN	NOISE 1	NOISE 2	INCR. 1	INCR. 2	RADIO 1	RADIO 2	MOTOR 1	MOTOR 2
(1)	95.3	78.2	58.2	85.9	70.6	91.8	87.6	94.7	64.7
(2)	94.7	94.1	92.1	92.9	87.6	91.8	86.5	94.7	70.0
(3)	92.9	90.0	91.8	90.0	80.0	88.2	83.5	91.2	78.8
(4)	91.8	91.8	92.4	92.9	84.7	92.4	87.6	91.8	70.6

Erkennungsraten auf den einzelnen Testdatensets (angegeben ist jeweils die Word-Accuracy in Prozent)



## Netzarchitektur



## Trainingsmengen

	Menge (1)	Menge (2)	Menge (3)	Menge (4)
CLEAN (ca. 30 dB SNR)	170 Samples	170 Samples	170 Samples	170 Samples
NOISE 1 (ca. 16 dB SNR)		170 Samples		170 Samples
NOISE 2 (ca. 8 dB SNR)			170 Samples	170 Samples
insgesamt	170 Samples	170 Samples	170 Samples	170 Samples

## Testergebnisse

Trainingsmenge	CLEAN	NOISE 1	NOISE 2	INCR. 1	INCR. 2	RADIO 1	RADIO 2	MOTOR 1	MOTOR 2
(2)	95.3	94.1	90.0	92.4	62.9	91.2	74.7	95.3	78.2
(3)	95.9	93.5	92.9	93.5	77.1	91.2	84.7	94.1	81.2
(4)	96.5	97.1	95.3	97.6	78.8	91.2	85.3	95.3	74.1

Erkennungsraten auf den einzelnen Testdatensets (angegeben ist jeweils die Word-Accuracy in Prozent)

