SPRACHSIGNALAUSWERTUNG MIT DEM EXPERTSYSTEM EXA 1630

Detlev Langmann
Technische Universität Dresden

1. Problemsituation

Vergleicht man den gegenwärtigen Stand der automatischen Spracherkennung (ASE) mit dem humanen Vorbildsystem, könnte man etwas vereinfacht formulieren, daß die künstliche Intelligenz zur Sprachsignalverarbeitung der eines Kleinkindes unter 3 Jahren funktionell entspricht. Die Erkennung einfach strukturierter Sätze aus wenigen Worten bei Wortschätzen um 1000 Worte kennzeichnen dieses Niveau.

Der Entwickler von automatischen Spracherkennungssystemen (ASE) befindet sich in folgender Problemsituation:

(P_1) Das **Problem** besteht in der Findung und Modellierung eines Zusammenhangs zwischen Signal-Input und symbolischen Output des sprachfunktionalen Systems. Das Sprachsignal ist unscharf in Relation auf enthaltene Nachrichten.

(P_2) Es existiert eine Vielzahl von **Teilmodellen**, deren Aussagen bezüglich (P_1) häufig als unvollständig, unscharf, zueinander schwach strukturiert und schwer formalisierbar zu charakterisieren sind. Die Art und Weise ihres Zusammenwirkens bei gezielter Reduktion lokaler Freiheitsgrade in einem aggregierten Modell ist weitgehend unklar.

(P_3) Eine **Lösungsstrategie** wird bevorzugt in der gezielten experimentellen Verknüpfung geeigneter Teilmodelle vermutet. Bekannte Restriktionen des Originalsystems können die potentielle Kombinationsvielfalt initialer Modellansätze wesentlich einschränken.

2. Expertsysteme - Möglichkeiten und Anforderungen

Expertsysteme werden als innovative **Forschungstechnologie** angesehen. Der Grundgedanke soll im folgenden angerissen werden.

In Expertsystemen sind Wissenserwerb, Wissensrepräsentation und Steuerstrukturen zur Wissensmanipulation und -validierung gegenüber nicht unmittelbar problemrelevanten Prozessen der formalen numerischen Datenverarbeitung und Organisation klar abgehoben. Sie wölben eine Grenzschicht bzw. Modelloberfläche auf, die das Wechselspiel von Modellentwicklung und Modellerkenntnis zur "kognitiven Symbiose" zwischen Experte und Expertensystem befördert. Nach Strukturierung des Problems (P_1) in Teilprobleme und deren Auflösung in relevante Teilmodelle (P_2) kann der Aufwand auf kognitive Elementaroperation zur Verknüpfung, Strukturierung und Verfeinerung dieser formalisierten Teilmodelle im Sinne von (P_3) gesenkt werden. Der Nutzer entwirft an der "Wissensschnittstelle" des Systems "einfach" neue Modelle aus der Verknüpfung von Teilmodellen, testet diese unmittelbar an der Datenbasis und korrigiert, adaptiert bzw. erweitert sie entsprechend dem erreichten Kenntnisstand. Die fortwährende Wissensanreicherung im Expertsystem während des Problemlöseprozesses schafft einerseits kognitive Freiräume des Experten für im aktuellen Problemzustand nicht formalisierbare bzw. kreative Denkoperationen und schränkt andererseits durch die zu erhaltende Konsistenz der Wissensbasis den Suchraum im Expertsystem weiter ein. Im Idealfall ermöglicht die unkomplizierte Beherrschung iterativer Problemraumportierungen zwischen Experte und Expertsystem eine Art "Bootstrapping" auf dem Wege zur Lösung. Hieraus resultiert im wesentlichen die von üblichen Auffassungen abweichende These des **"Expertensystems für Experten"** /5/.

Für Probleme der ASE lassen sich folgende Forderungen an Expertsysteme ableiten:

1.) Das Verstehen von Benutzereingaben durch eigenständige Transformation in eine interne Repräsentationsform (**Dialogkomponente**).

2.) Verfügbarkeit einer **"Methodenbank"** mit etwa folgendem Reservoir:
   - Algorithmen zur Störunterdrückung, Signalrestauration und Signalvorverarbeitung (objektive Signalanalyse)
   - Algorithmen zur Gewinnung empfindungsspezifischer Merkmale (psychophysikalische Signalanalyse, Merkmalextraktion)
   - Algorithmen zur zeitlichen und spektralen Reduktion des Signals bei Erhaltung wesentlicher informationstragender Anteile
3.) Vorhandensein einer **Datenbasis und Wissensbasis** mit einfachen Möglichkeiten zur Modifikation, Manipulation, Erweiterung und Wartung.
4.) **Wissenserwerbskomponente** mit Möglichkeiten zum Neulernen, Adaptieren und Anreichern von Modellwissen aus dem Sprachsignal.
5.) Verfügbarkeit einer leistungsfähigen, angepaßten **Inferenzkomponente** zur Problemauflösung. Für "signalnahe" (und unscharfe) Schlußfolgerungen ergibt sich zumindest die notwendige Aktivierbarkeit von Inferenzmechanismen zur
   - Ableitung einer ersten (und unscharfen) symbolischen Repräsentation aus vorliegenden systemorientierten Objektbeschreibungen und Modellwissen über akustisch-phonetische Eigenschaften des Sprachsignals
   - Verknüpfung (unscharf repräsentierter) Symbolfolgen gemäß der Lösungsstrategie (P_3) zu Minimalsegmenten der Erkennung (z.B. Silben).
6.) "Anregende" Nutzerpräsentation aktueller Problem- und Systemzustände (**Erklärungskomponente**) mit einem Maximum an akustisch, graphisch und verbal gestützter Animation und Interpretation (kognitive Bündelung!).
7.) Experimentierfreudigkeit durch **kurze Antwortzeiten** (möglichst < 2s) des Systems wenigstens für Zwischenlösungen.
8.) Möglichkeit der **automatischen Programmgenerierung** für den vom Nutzer akzeptierten Lösungszustand.

Dieser Forderungskomplex impliziert höchste Ansprüche an die zugrundeliegende Hard- und Softwaretechnologie und ist Gegenstand zahlreicher internationaler Forschungsprojekte.

3. Fuzzy-Konzept

Die nuancierte Skala menschlicher Denk-, Kommunikations- und Handlungsweisen übertrifft die Leistungsfähigkeit automatischer Verfahren in Prozessen mit unvollständiger, unsicherer und vager Informationssituation. Ein eindrucksvolles Beispiel hierfür sind die beachtlichen Ergebnisse geschulter Spektrogrammleser (ZUE). Charakteristisch ist dabei das Agieren mit begrifflich qualitativen Grobvorstellungen anstelle exakt mathematisch gefaßter Modelle. An dieser Stelle versuchen Konzepte auf der Grundlage der Theorie der unscharfen Mengen einzusetzen.

Die Grundidee der **Theorie der unscharfen Mengen** ("fuzzy sets") nach ZADEH /6/ besteht darin, gemäß einem **Bewertungskriterium** z den Elementen einer scharfen (klassischen) Grundmenge $\underline{U}$ graduelle anstelle binärer Bewertungen zuzuweisen. Hieraus resultiert die unscharfe Menge $\sigma_U(z)$, die durch eine **Zugehörigkeitsfunktion** $\mu_z(u)$ charakterisiert werden kann:

$$\mu_z(u) : \quad \underline{U} \dashrightarrow \mathbb{R}' \quad \text{mit} \quad \mathbb{R}' = [I_{min}, I_{max}] \; ; \quad \mathbb{R}' \subseteq \mathbb{R}$$

$\sigma_U(z)$ heißt dann unscharf repräsentierte Teilmenge oder unscharfe Teilmenge auf $\underline{U}$. Bevorzugt wird oft die Bewertung im reellen Einheitsintervall [0 ,1]. Die Zugehörigkeitsfunktion $\mu_z(u)$ definiert dann in [0,1] monoton steigend (fallend) den wachsenden (fallenden) Grad der Zugehörigkeit von u zu z. Der Grad der Zugehörigkeit wird auch kurz "Zugehörigkeit" genannt.

Unschärfe-Konzepte werden häufig verwendet wegen
- der Unschärfe und Inkonsistenz eintreffender Analysedaten bezüglich abzuleitender Reaktionsklassen (P_1)
- des Nichtvorliegens massenhafter Beobachtungen dieser Reaktionsklassen im statistischen Sinne (meist durch unterschiedliche Randbedingungen diktierte Erschwernis/ Unmöglichkeit ihrer Erzeugung und Auswertung)

einerseits und andererseits infolge
- unsicheren (vagen) Wissens über die Ein- /Ausgabebeziehungen betreffender Systeme im Sinne von (P_2).

Diese Argumente wurden bereits zur Kennzeichnung der typischen Problemsituation des Entwicklers von Systemen zur ASE herangezogen. Für den Entwickler von ASE bieten Unschärfe-Konzepte günstige Ansatzpunkte, weil sie nicht zwingend auf probabilistische Bewertungen und den hierfür zutreffenden Verknüpfungsmöglichkeiten festgelegt sind. Sie verfügen über eine breite Palette flexibler Verknüpfungsarten, die das **problemadäquate** (z.B. auf die Perzeption akustischer Signale bezogene) Zusammenwirken von Modellkomponenten ermöglichen. Der wahrscheinlichkeitstheoretische Zugang ist nur dann impliziert, wenn das Bewertungskriterium so gewählt wird, daß Merkmalwerte mit statistischer Auftrittschance auch eine hohe Zugehörigkeit erhalten. Häufig werden Bewertungskriterien des Grades der Zugehörigkeit oder der Möglichkeit verwendet, die enger auf perzeptive Ähnlichkeitsurteile beziehbar sind als Kriterien der Auftrittshäufigkeit.

Für die Wissensrepräsentation von akustisch-phonetischen Eigenschaftsklassen im m-dimensionalen Merkmalraum $\underline{U}^m$ wurde die von BOCKLISCH entwickelte Potential-Zugehörigkeitsfunktion $\mu_z(\vec{u}, \underline{p})$ /1/ aufgrund ihrer hohen Flexibilität und überschaubaren Handhabbarkeit ihrer Parameter $\underline{p}$ bevorzugt /3/.

4. Das Expertsystem EXA 1630

4.1. Überblick

Das Expertsystem EXA 1630 bietet einen Modellrahmen, der dem Nutzer die experimentelle Entwicklung und Simulation einer **wissensbasierten Signalauswertung** ermöglicht /5/. Aus dem Doppelcharakter von Sprache, Signal an sich und gleichzeitig Zeichen für etwas zu sein, ergab sich der Anspruch, ausgewählte Methoden der Signalauswertung sowohl in analytischen als auch in bewertenden Prozeduren experimentell verfügbar zu machen. Folgende sprachrelevante Charakteristika wurden in den "Expertenraum" von EXA 1630 portiert:

1. Orts- und zeitspezifische Prozeduren zur Vektorfolgentransformation
2. Psychoakustisch motivierte Bewertungsfolgen als (Faltungs-)Kerne für Folgentransformationen
3. Unschärfekonzept zur Folgenauswertung auf der Basis einer äußerst flexiblen Potential-Zugehörigkeitsfunktion
4. Eigenständige Lern- und Editierkomponente zur Bildung unscharfer Modelle mit Potential-Zugehörigkeitsfunktionen als Repräsentanten akustisch-phonetischer Eigenschaftsklassen
5. Regelinterpreter mit Fuzzy-Logik zur zeitlich asynchronen Verknüpfung unscharf repräsentierter Signaleigenschaften (z.B. zum Silbenaufbau)

Das angestrebte "Bootstrapping" zwischen Experte und Expertensystem wurde befördert durch farbgraphisch gestützte Beobachtungs-, Simulations- und Manipulationsmöglichkeiten von aktuellen Zuständen der Daten- und Wissensbasis. Aus Bild 1 ist die Gesamtstruktur des Expertsystems EXA 1630 zu entnehmen. EXA 1630 wurde in den Programmiersprachen FORTRAN77 und MACRO-SM auf dem Rechner K1630 implementiert.

4.2. Datenbasis und Wissensbasis

Die Datenbasis vermittelt dem Expertensystem systeminterne Beschreibungen von Sprachsignalen. Hierin werden Vektorfolgen aller möglichen Beschreibungsebenen des Systems abgelegt. Beginnend mit primären $\langle\vec{x}(n)\rangle$ und sekundären $\langle\vec{u}(n')\rangle$ Merkmalvektorfolgen über Sympathievektorfolgen $\langle\vec{\mu}_z(n'')\rangle$ bis hin zu symbolischen Vektorfolgen $\langle\vec{y}(\nu)\rangle$ liegen in der Datenbasis **aktuelle Kenntnisbeschreibungen** des Systems zur anliegenden Objektrealisierung vor.

Die Wissensbasis enthält demgegenüber relativ **beständige Beschreibungen zum Objektbereich** (Wissen) in Form von Wichtungskoeffizienten, Parametern und Regeln. Datenbasis und Wissensbasis bestimmen also den "Gesichtskreis" des Expertensystems. Während die Datenbasis im Ergebnis eines Mehrstufenprozesses die

fortschreitende aktuelle Kenntnis des Systems zu einer Objektrealisierung widerspiegelt (Wissensanwendung), führt die Optimierung dieses Prozesses über viele Objektrealisierungen in der Wissensbasis zur Anreicherung formalisierten und übergreifenden Modellwissens zum Objektbereich (Wissenserwerb). Das Zusammenwirken zwischen Daten- und Wissensbasis über Merkmaltransformationen, Wissenserwerb und -anwendung wird durch die Kerntasks **EXA, EVOLON** und **URI**, vermittelt.

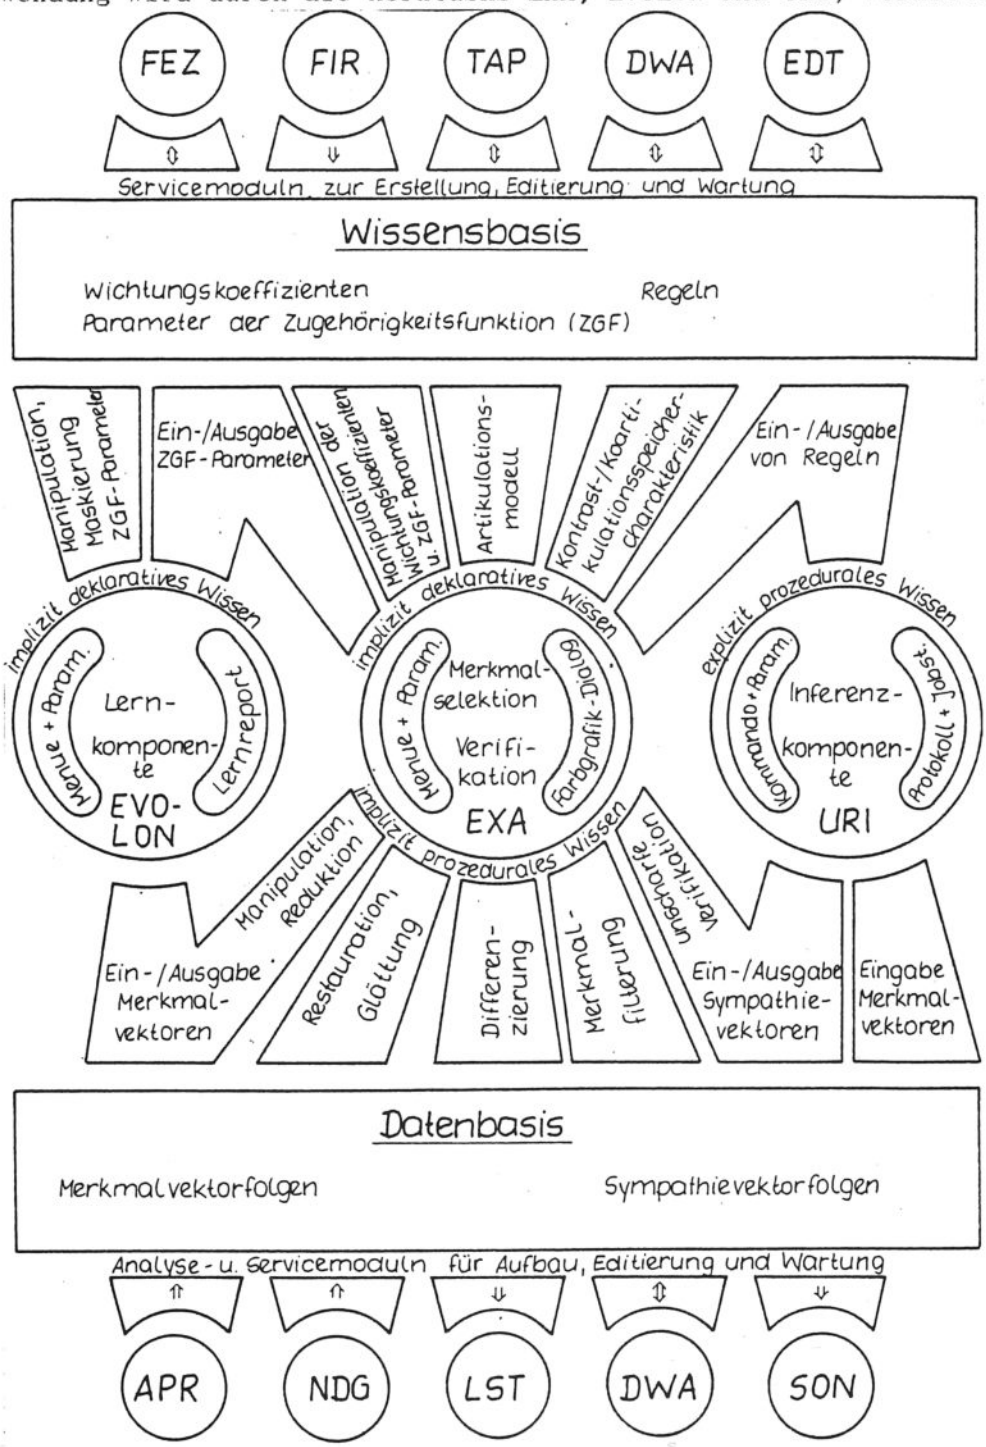

Bild 1 Übersichtsschema zum experimentellen Expertsystem EXA 1630

4.3. Experimentierkomponente EXA

Die Experimentierkomponente EXA ermöglicht zeitlich orientierte Folgentransformationen zur Vorverarbeitung, Merkmalextraktion und unscharfen Verifikation akustisch-phonetischer Eigenschaftsklassen aus mehrdimensionalen Folgen von Sprachanalysedaten.

Unter Anwendung des **Grundprinzips der zeitspezifischen Folgenverarbeitung** wurden Algorithmen zur
- Zeitreduktion durch Mittel- bzw. Maximalwertbildung
- Glättung/ Signalrestauration
- Differenzierung
- Merkmalfilterung

implementiert. Die Algorithmen zur Differenzierung und Merkmalfilterung sind durch ladbare Wichtungskoeffizienten modifizierbar, wobei psychoakustisch motivierte Koeffizienten in der Wissensbasis des Systems dem Nutzer zur Verfügung stehen. Der Algorithmus zur Merkmalfilterung ist darüberhinaus durch die Auswahl des Verknüpfungsoperators (Dilatations-, Erosions-, FIR-Filter) steuerbar. Interaktive Manipulationen, z.B. Segmentieren, Etikettieren und Werteänderungen, können mittels einer speziellen Cursorgraphik vorgenommen werden. Daraus entstehende Merkmalvektorfolgen können sowohl zum Lernen unscharf repräsentierter Eigenschaftsklassen der Lernkomponente EVOLON zugeführt, als auch der unscharfen Verifikation dieser Eigenschaftsklassen mit EXA unterworfen werden.

Die unscharfe Verifikation von Eigenschaftsklassen des Sprachsignals wurde unter Anwendung des **Grundprinzips der ortsspezifischen Folgenverarbeitung** mit konjunktiven Verknüpfungsoperatoren unterschiedlicher Restriktivität implementiert (Bild 2).

Aus Bild 3 wird am Beispiel der akustisch-phonetischen Eigenschaftsklasse "Lautübergang Nasal-heller Vokal" deutlich, daß die Zunahme der Modellrestriktivität infolge der Konjunktionen conj* eine stärkere pessimistische Ausprägung des Gesamtzugehörigkeitsverlaufes nach sich zieht. Vorteilhaft können "Störungen", d.h. Zugehörigkeitswerte an unerwünschten Stellen, im Sprachsignal unterdrückt werden, wobei aber gleichzeitig die Bedämpfung relevanter Ausprägungen im Zugehörigkeitsverlauf in Kauf zu nehmen ist.

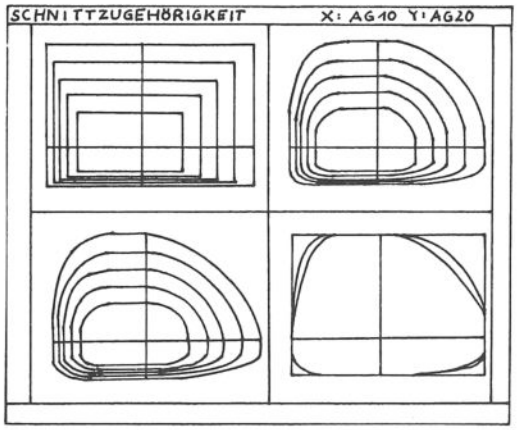

Bild 2 Linien gleicher Bewertung einer Eigenschaftsklasse im 2-dimensionalen Merkmalraum unter Verwendung zunehmend restriktiver Konjunktionen (conj1...3) zur Verknüpfung 1-dimensionaler Schnittzugehörigkeitsfunktionen

links oben: conj1 rechts oben: conj2
links unten: conj3 rechts unten: conj1, conj2, conj3

Jede Eigenschaftsklasse z wird durch Parameter $\underline{p}$ der Zugehörigkeitsfunktion repräsentiert, die in die Wissensbasis ladbar sind. Im Ergebnis der unscharfen Verifikation entsteht ein Zugehörigkeitsverlauf $\langle \mu_z(n'') \rangle$ zur Eigenschaftsklasse z. Die serielle Auswertung unscharfer Verifikationen ermöglicht den Aufbau einer Sympathievektorfolge $\langle \vec{\mu}_z(n'') \rangle$, die dann als aktuelle Kenntnisbeschreibung des Systems über $\langle \vec{x}(n) \rangle$ in die Datenbasis rückgeschrieben werden kann. In der Wissensbasis des Systems verbleibt Wissen zur Überführung $\langle \vec{x}(n) \rangle \dashrightarrow \langle \vec{u}(n') \rangle \dashrightarrow \langle \vec{\mu}_z(n'') \rangle$ in Form von Bewertungsfolgen und Parametern der Zugehörigkeitsfunktion.

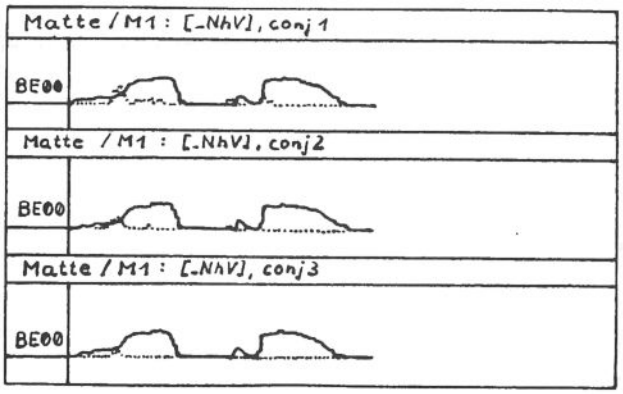

Bild 3 Zugehörigkeitsverläufe zur Eigenschaftsklasse "Nasal-heller Vokal" unter Verwendung von Konjunktionen (conj*) mit zunehmenden "Pessimismus" (von oben nach unten)
Linie (dick): Betragsverlauf Linie (dünn): Zugehörigkeitsverlauf

4.4. Lernkomponente EVOLON

Die Lernkomponente EVOLON bildet aus einlaufenden Merkmalvektoren $\langle\vec{u}(n')\rangle$ unscharfe Cluster, die durch die Parameter $\underline{p}$ der Zugehörigkeitsfunktion $\mu_z(\vec{u}, \underline{p})$ repräsentiert werden /1/. Sie verarbeitet die Lernprobe zeitscheibenweise, d.h. jeder Merkmalvektor wird ohne unmittelbare Berücksichtigung seiner Nachbarn "gemustert". Das Programm verfügt über einen reservierten Speicherbereich für die parametrischen Clusterrepräsentanten $\mu_z(\vec{u}, \underline{p})$ (Clusterbasis). Bezüglich der Clusterbasis arbeitet das Lernverfahren rekursiv. Die Fuzzy-Cluster sind während des Lernens Prozessen
- des Entstehens und Verlöschens (Merken/Vergessen),
- des Wachstums und der Schrumpfung (Einprägen/Verblassen),
- des Driftens im Merkmalraum und
- der Verschmelzung und Spaltung

ausgesetzt /1/. Werden vor dem Auslösen dieser Prozesse bereits Clusterrepräsentanten in die Clusterbasis geladen (Startcluster), arbeitet das Lernprogramm adaptiv. Aus der Sicht des Programms unterscheiden sich Lernen und Adaption nach Belegung der Clusterbasis nicht mehr. Somit kennzeichnet "Lernen" bevorzugt die "Einschwingphase" des Verfahrens, in der oben genannte Prozesse in der Clusterbasis noch weitgehend der Kurzzeit-Dynamik der Lernprobenfolge entsprechen können ("System aus dem Nullzustand"). Die adaptive Arbeitsweise dämpft diese Prozesse und folgt mehr der Langzeit-Dynamik der Lernprobe.
Über Steuerparameter kann der Nutzer
- die Maskierung, Selektion und Normierung der Merkmalvektoren,
- die Gestalt der Elementarcluster,
- die Verschmelzungs-, Spaltungs- und Löschschwelle,
- die Wachstums- und Vergessensfunktion,
- den Protokollmodus und weitere Arbeitsmodi des Programms

festlegen.

4.5. Inferenzkomponente URI

In Expertensystemen leitet man Schlußfolgerungen im allgemeinen mit Hilfe von Inferenzkomponenten ab, im besonderen auch von Regelinterpretern. Regelinterpreter wählen in Abhängigkeit vom formulierten Problem Regeln aus, prüfen die Voraussetzungen ihrer Anwendbarkeit, wenden sie auf Fakten bzw. Daten an und führen das "Feuern" der Regel (Aktion) aus, wenn ihr Bedingungsgefüge erfüllt ist. Die Schlußfolgerung einer Regel wird jedoch vage, wenn Fakten oder die Regel selbst mit Unsicherheiten behaftet sind. Gerade davon ist in einem Expertensystem zur Auswertung von Sprachsignalen auszugehen.

Für die Repräsentation von sprachlichen Minimalsegmenten wird eine Verarbeitungskomponente gebraucht, die Fuzzy-Cluster bzw. Eigenschaftsklassen $\mu_z(\vec{u}, \underline{p})$

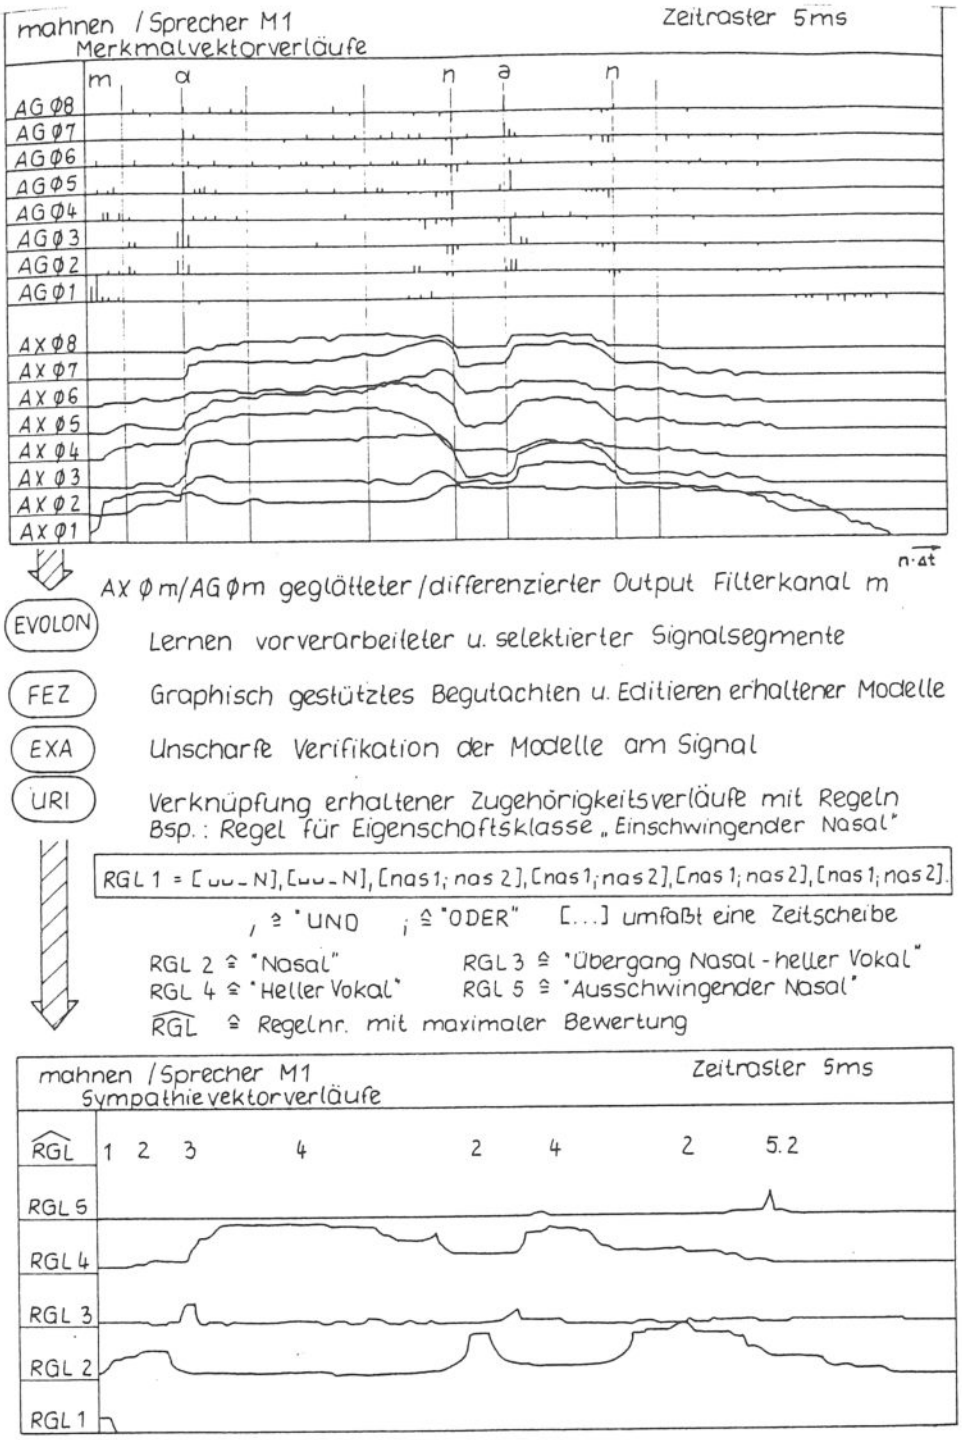

Bild 4 Unscharfe Signalauswertung nach akustisch-phonetischen Eigenschaftsklassen

zu einer **Folge komplexer Eigenschaften** verknüpft. Es soll die Möglichkeit entstehen, Hypothesen, wie sie aus phonetisch-phonologischen Überlegungen des Experimentators resultieren, einfach formulieren zu können und an akustisch-phonetisch orientierten Kenntnisbeschreibungen $\langle \vec{\mu}_z(n'') \rangle$ über ein vorliegendes Signal zu testen.

Die Inferenzkomponente URI realisiert als weitere Kerntask des Expertensystems die experimentelle Verkopplung zwischen Datenbasis und Wissensbasis durch unscharfe Auswertung von Daten durch Regeln. Diese werden in einer definierten Regelsprache nach der Inferenz "**modus ponendo ponens**" abgearbeitet:

Prämisse:	Z $Z^* \dashrightarrow Y$	bzw.	**WENN**	Bedingungen erfüllt
Konklusion:	$Z \circ (Z^* \dashrightarrow Y)$		**DANN**	führe Aktion aus.

Eine Regel wird anwendbar oder aktiv, wenn für alle Eigenschaften Z ihres Bedingungsgefüges Z^* Kenntnisbeschreibungen in der Datenbasis vorliegen. Im Bedingungsgefüge Z^* (WENN-Zweig) werden Kenntnisbeschreibungen zu Eigenschaften einer Zeitscheibe mit Kenntnisbeschreibungen über Eigenschaften der folgenden Zeitscheiben mittels UND- bzw. ODER-Operatoren verknüpft. Die Verknüpfungen gehorchen den Gesetzen der Fuzzy-Logik. Die Schlußfolgerung der Regel (DANN-Zweig) wird Aktion genannt, weil in die Datenbasis erhaltene Regelbewertungen eingetragen werden ("Feuern der Regel"). Jede Regelbewertung charakterisiert die Konsistenz der Regel zu den in ihrem Verarbeitungsfenster vorliegenden Kenntnisbeschreibungen und liefert mithin eine unscharfe Aussage über (das Minimalsegment) y. Praktisch "feuert" eine aktive Regel also immer, nur "mehr oder weniger stark". Unterschreitet die erreichte Regelbewertung jedoch einen festlegbaren Schwellwert, werden "Nullen" gefeuert, um für Vergleichszwecke die entstehende Regelbewertungsfolge nicht zu unterbrechen.

Verifizierte Hypothesen können in die Wissensbasis eingelagert werden und bilden die Eckpfeiler für einen Brückenschlag zur symbolischen Beschreibung des Sprachsignals.

5. Anwendung und Ergebnisse in der akustisch-phonetischen Signalauswertung

Die Erarbeitung eines Lösungspfades im Expertenraum von EXA 1630 wurde an der Ableitung von akustisch-phonetischer Eigenschaftsklassen ,die Lautübergänge beschreiben, experimentell untersucht (s. Bild 4, RGL3, RGL5) /4/, /5/.

Subjektiv etikettierte Lautübergänge in Einzelworten wurden bereits zu 83% richtig detektiert. Die untersuchten Sprachsignale weisen eine hohe Selektivität der Zugehörigkeitsverläufe für die entsprechenden Lautübergangsklassen auf. Die unscharfe Detektion dieser potentiellen Segmentkonstituenten ist häufig äußerst "scharf" ausgeprägt und besitzt meist eine gipflige Form mit einer Basisbreite bis zu 30 ms. Bemerkenswert ist, daß dieses Ergebnis mit **einem** Lautübergangsmodell pro Klasse für (4) **verschiedene und ungeübte** Sprecher beiderlei Geschlechts unter Anwendung einer einfachen Modelladaption erzielt wurde. Hinzu kommt, daß neben der zeitlichen Anzeige dieser Segmentkonstituenten eine Information über ihre akustisch-phonetischen Eigenschaften zur Verfügung steht.

Anstelle einer verfrühten Entscheidung für die bestbewertete Eigenschaft sollte jedoch die Information, in welchem Maße Eigenschaften im Sprachsignal ausgeprägt sind (Zugehörigkeit), berücksichtigt werden, um sprachliche Minimalsegmente aufzubauen. Hierfür bietet die Inferenzkomponente des Expertsystems angepaßte und in Bild 4 angedeutete Möglichkeiten.

/1/ Bocklisch, S. F.: Prozeßanalyse mit unscharfen Verfahren. - Berlin: Verlag Technik, 1987

/2/ de Mori, R.: Computer Models of Speech Using Fuzzy Models. - New York: Plenum Press, 1983

/3/ Langmann, D.; Mittig, A.: Einbindung psychoakustischer Komponenten in das Erkennerkonzept V. Forschungsbericht 26/86. - Dresden, Techn. Univ., Sektion Informationstechnik, 1986

/4/ Langmann, D.: Unscharfe Segmentierung von Sprachsignalen. Tagungsmaterial zur 8. Tagung Akustik 20./21.1.1989. - Berlin: Physikalische Gesellschaft der DDR, 1989. - S. 131 - 136

/5/ Langmann, D.: EXA 1630 - Einsatz einer Experttechnologie zur Sprachsignalauswertung mit unscharfem Zugang. - 1990. - Dresden, Techn. Univ., Diss. A (eingereicht)

/6/ Zadeh, L. A.: Fuzzy Sets. Information and Control. - 8(1965). - S. 338 - 353