Feature Transformation Strategies for a Robot Learning Problem

[Seabra Lopes and Camarinha-Matos, 1998] und [Seabra Lopes and Camarinha-Matos, 1999]

Dirk Münstermann

18. Januar 2000

Inhaltsübersicht

Roboterprogrammierung durch Demonstration

- Interaktion mit dem Menschen (Tutor)
- Benutzerinterface zur Erleichterung des Wissenstransfers
- Lernfähigkeit zur Generierung neuen Wissens.
- Trainingsphase:
  - Vorführung von Beispielen des Wunschverhaltens und
  - künstliche Herbeiführung von typischen Ausnahmesituationen (Fehlern).
  - Generierung von Fertigkeiten und dem zugehörigen Überwachungswissen aus den Sensordaten.

SKIL (structured knowledge generated by inductive learning)

- SKIL ist ein Lernverfahren zum Begriffslernen.
- Der Entscheidungsbaum wird wie bekannt nach dem Kriterium der Unterscheidungskraftmaximierung aufgebaut.
- Ein Attributaktivierungsausdruck (A_i, a_{ij}, A_k) zeigt folgendes: Wenn der Wert von A_i a_{ij} entspricht, so soll das Attribut A_k in die Menge der Attribute für die Weiterführung des Induktionsprozeß aufgenommen werden.

  Bsp: $(failure\_type,\ \mathtt{collision},\ \mathtt{obj}\_size)$

Bsp: Hierarchie von Attributaktivierungsausdrücken

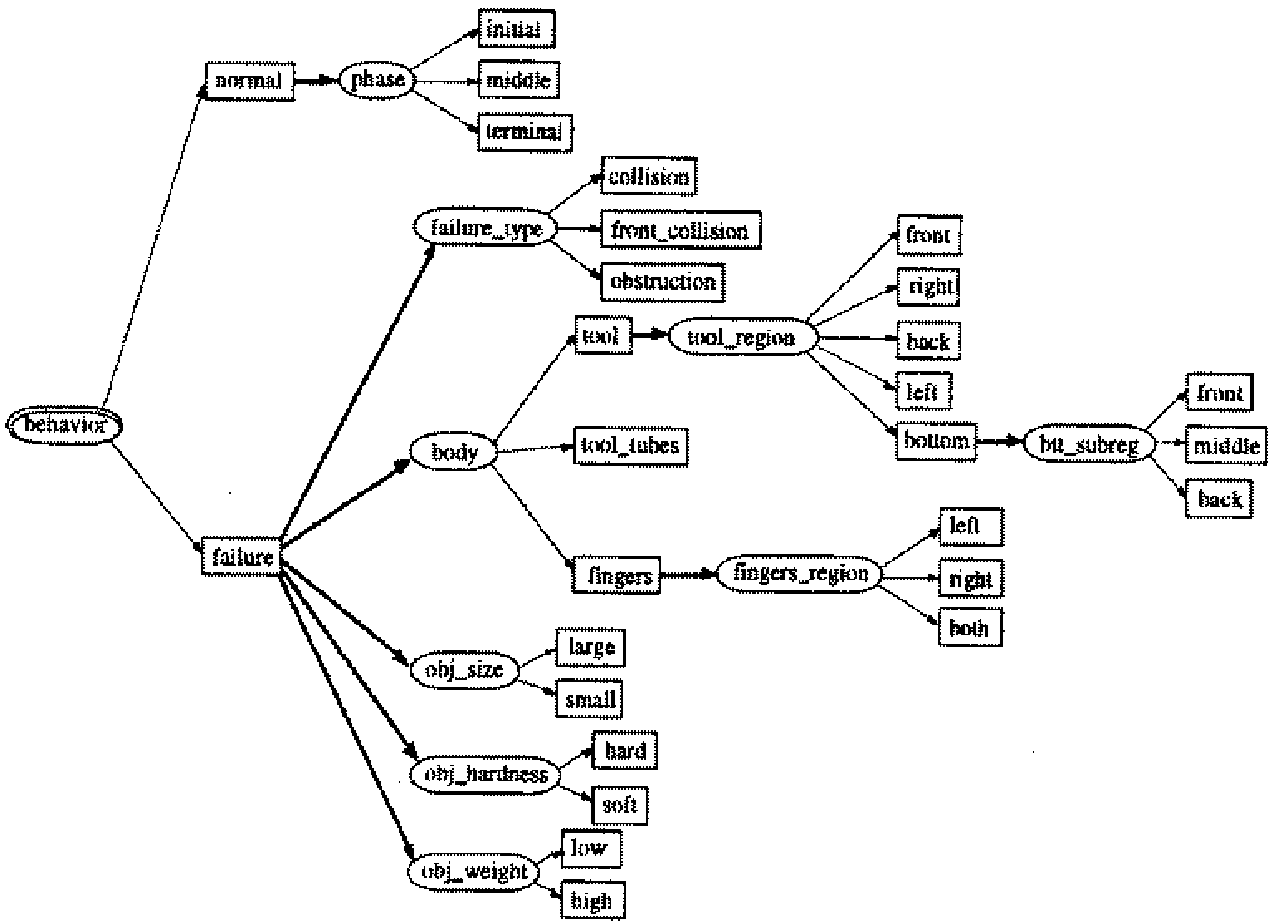

Ausschnitt eines Entscheidungsbaumes

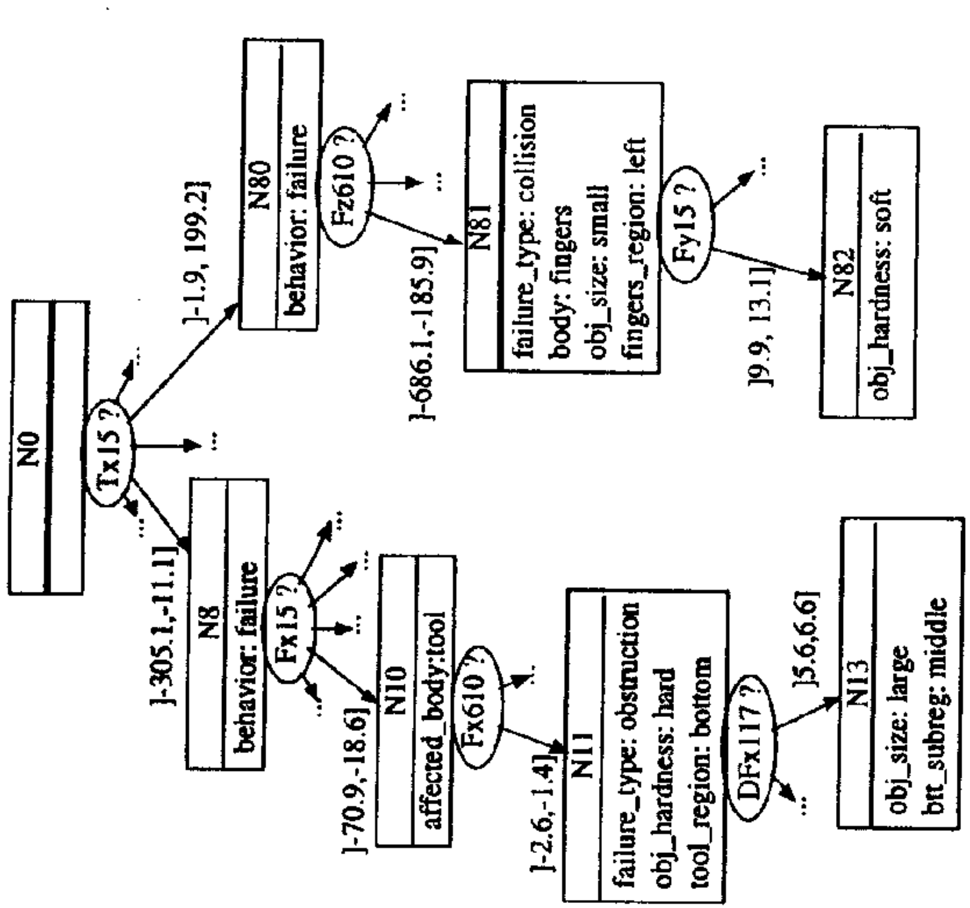

Fallstudie:
The Pick and Place Task

- Aufnehmen, Bewegen und Absetzen einen Teiles.
- Von den in dieser Operation beinhalteten Primitiven werden die folgenden drei Primitive betrachtet:
  1. Annäherung an die Ergreifposition (Approach-Grasp),
  2. Transportieren eines Teiles (Transfer) und
  3. Annäherung an die Endposition (Approach-Ungrasp)
- Lernaufgabe: Erkennung von speziellen Fehlern durch Bildung von Überwachungswissen

Trainingsphase

- wiederholte Ausführung der Operationen
  - 88 Beispiele für Approach-Grasp
  - 47 Beispiele für Transfer
  - 117 Beispiele für Approach-Ungrasp
- Simulation verschiedener Fehler z.B.
  - Absetzen des aufgenommenen Teiles während einer Bewegung,
  - Kollision des Roboterarms oder des aufgenommenen Teiles mit einem anderen Teil.
- Zu jedem Fehler wird eine Folge von Sensordaten, die eine Ereignisfolge von der Fehlererkennung zur Stabilisierung des Systems beschreibt, gebildet und durch eine genau Fehlerbeschreibung des Operators ergänzt.
- Dieses ermöglicht dem Lerner die Unterscheidung zwischen alternativen Fehlerbeschreibungen.

Merkmale und Sensoren in der Fallstudie

- Betrachtung der folgenden Merkmale (6 Variablen):
  - f_x, f_y und f_z für Kraftsensoren in X, Y und Z Richtung
  - t_x, t_y und t_z für Drehmomentsensoren in X, Y und Z Richtung
- Ein Merkmalvektor besteht aus 15 Sensorwerten (z.B. $\overline{p} = \overline{f}_x$) $\overline{p} = (p_1, \cdots, p_{15}) \in \mathfrak{R}^{15}$. (15 ist das Zeitintervall, das einen typischen Fehler beinhaltet.)
- In dem Überwachungsfenster werden die 6 Merkmalvektoren für Kraft und Drehmoment zusammengefaßt. $(\overline{f}_x, \overline{f}_y, \overline{f}_z, \overline{t}_x, \overline{t}_y, \overline{t}_z)$
- Die Anzahl der Merkmale innerhalb des Überwachungsfensters beträgt $(3 + 3) \cdot 15 = 90$.

Merkmaltransformation

- Vorverarbeitung der Daten
- Anwendung der Lernverfahren auf die vorverarbeiteten Daten
- Idee: Durch Transformation der unsprünglichen Merkmale sollen neue Merkmale erzeugt werden, die für Lernverfahren leichter zu unterscheiden sind.
- Eine Merkmaltransformationsstrategie ist eine Abbildung $f : \Re^d \longrightarrow \Re^k$, die einen d-dimensionalen Merkmalvektor in einen k-dimensionalen Merkmalvektor transformiert.
- Jede Merkmaltransformationsstrategie erzeugt mit Hilfe der ihr zugeordneten Merkmaltransformationsfunktionen einen neuen Merkmalvektor.

Merkmaltransformationsfunktionen I

Die Merkmalvektoren werden als Zeilenvektor aufgefaßt, d.h. das Zusammenfügen zweier Merkmalvektoren $\overline{f} \in \mathfrak{R}^m$ und $\overline{g} \in \mathfrak{R}^n$ erzeugt einen Merkmalvektor $\overline{h} \in \mathfrak{R}^{m+n}$ mit

$$h_i = \begin{cases} f_i & , i = 1, \cdots, m \\ g_{i-m} & , i = m+1, \cdots, m+n \end{cases}$$

Der **Durchschnitt** eines Merkmalvektors $\overline{p}$ zwischen zwei Instanzen m und n mit $1 \leq m \leq n \leq 15$ ist wie folgt definiert:

$$A(\overline{p}, m, n) = \frac{\sum_{i=m}^{n} p_i}{n - m + 1} \tag{1}$$

Die **Durchschnittsveränderung** eines Merkmalvektors $\overline{p}$ zwischen zwei Instanzen m und n mit $1 \leq m \leq n \leq 15$ ist wie folgt definiert:

$$D(\overline{p}, m, n) = \frac{p_n - p_m}{n - m} \tag{2}$$

Merkmaltransformationsfunktionen II

Genereller Trend in dem Merkmalvektor $\overline{p}$ ist steigend, falls $\mathrm{trend}(\overline{p}) = 1$ oder fallend, falls $\mathrm{trend}(\overline{p}) = -1$:

$$\mathrm{trend}(\overline{p}) = \begin{cases} 1 & \mathit{Wenn}\ A(\overline{p}, 1, 5) < A(\overline{p}, 11, 15), \\ -1 & \mathrm{sonst.} \end{cases}$$

Die **Monotonie** von $\overline{p}$ berechnet sich wie folgt:

$$M(\overline{p}) = \sum_{i=1}^{14} \mathrm{mon}(\overline{p}, i) \tag{3}$$

wobei die Funktion $\mathrm{mon}(\overline{p}, i)$ testet, ob der generelle Trend von $\overline{p}$ sich zwischen den Instanzen p_i und p_{i+1} fortsetzt:

$$\mathrm{mon}(\overline{p}, i) = \begin{cases} 1 & \mathit{Wenn}\ p_i \cdot \mathrm{trend}(\overline{p}) < p_{i+1} \cdot \mathrm{trend}(\overline{p}), \\ 0 & \mathrm{sonst.} \end{cases}$$

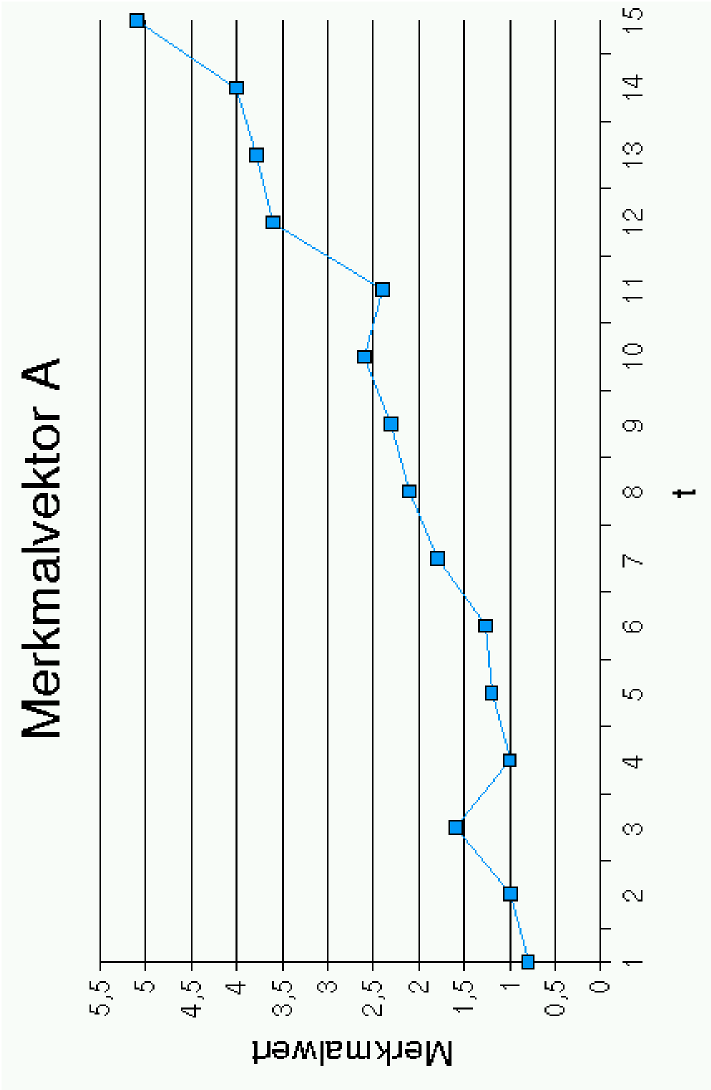
Merkmalvektor A
Merkmalwert
t
0 0,5 1 1,5 2 2,5 3 3,5 4 4,5 5 5,5
1 2 3 4 5 6 7 8 9 10 11 12 13 14 15

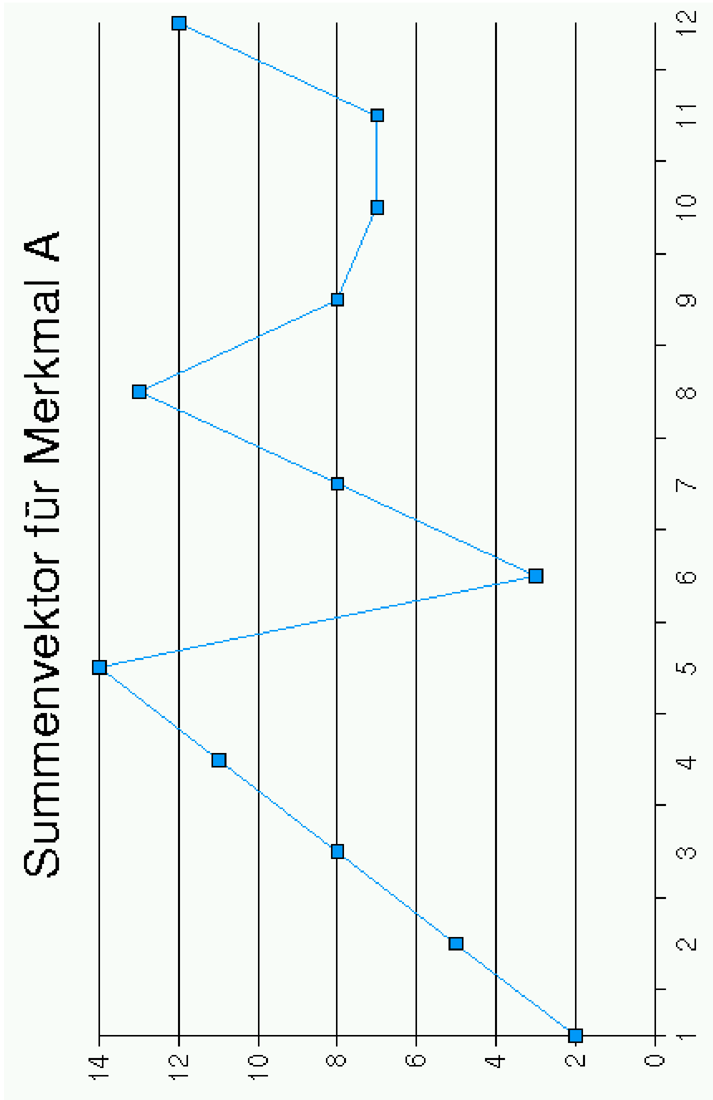
Summenvektor für Merkmal A
0 2 4 6 8 10 12 14
1 2 3 4 5 6 7 8 9 10 11 12

Merkmaltransformationsfunktionen III

Betrachten wir nun Merkmaltransformationsfunktionen, die mehrere Merkmalvektoren als Eingabe aufweisen.

$$\overline{r} = R_{2D}(\overline{a}, \overline{b}) \Leftrightarrow r_i = \sqrt{a_i^2 + b_i^2} \text{ für } i = 1, \ldots, 15 \tag{4}$$

$$\overline{r} = R_{3D}(\overline{a}, \overline{b}, \overline{c}) \Leftrightarrow r_i = \sqrt{a_i^2 + b_i^2 + c_i^2} \text{ für } i = 1, \ldots, 15 \tag{5}$$

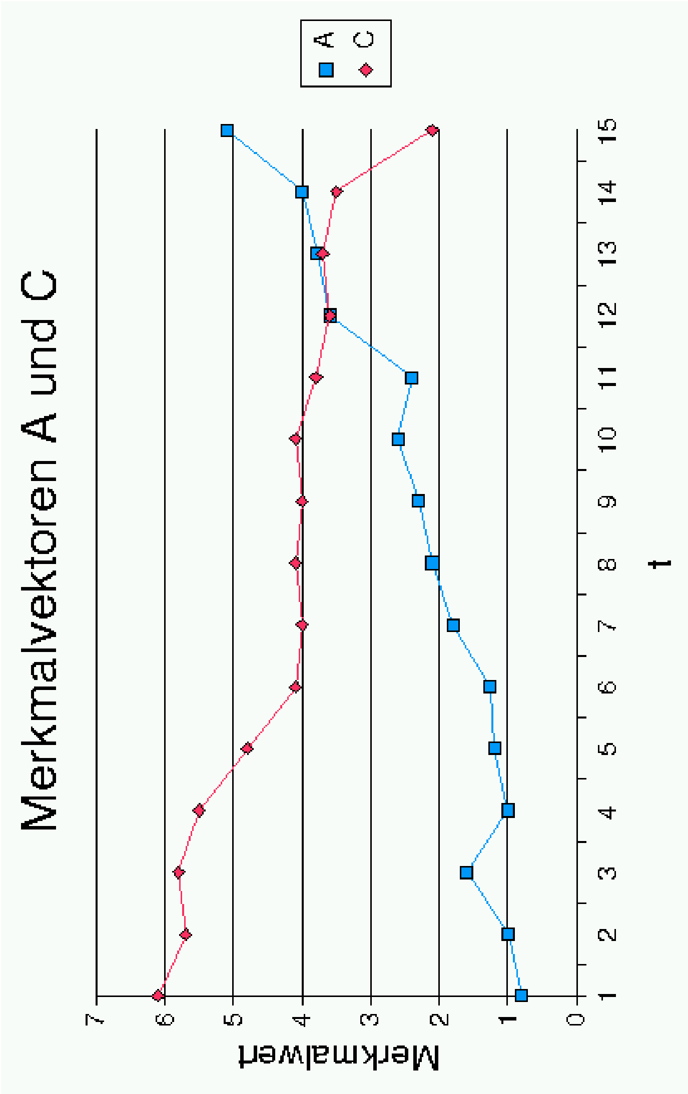
Merkmalvektoren A und C
A
C
Merkmalwert
t

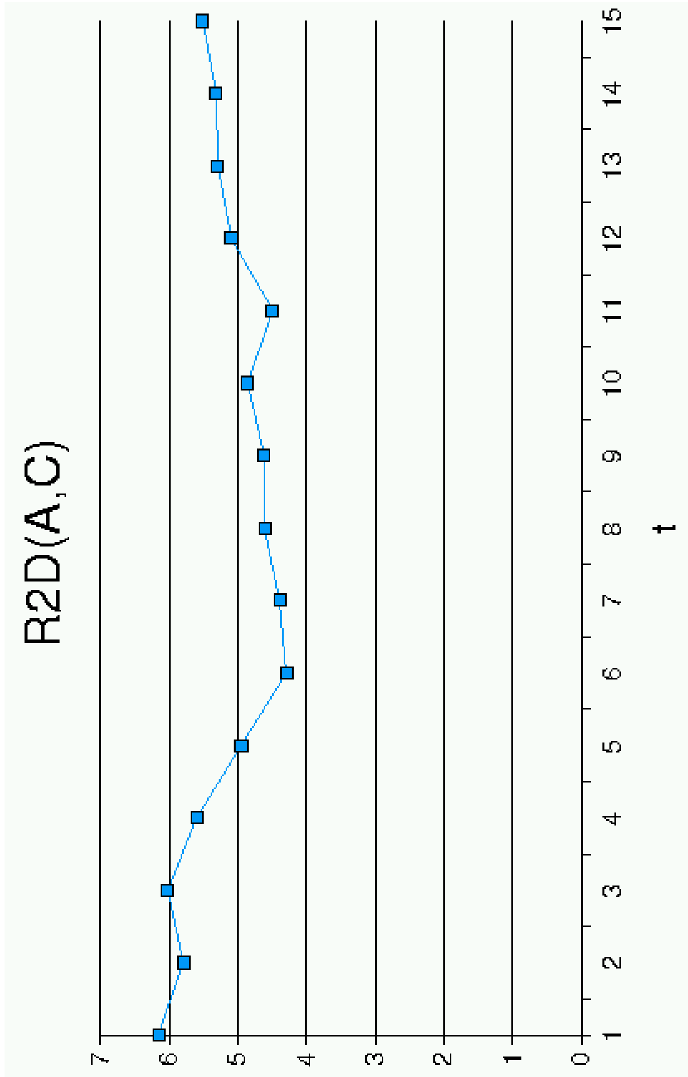
R2D(A,C)
t

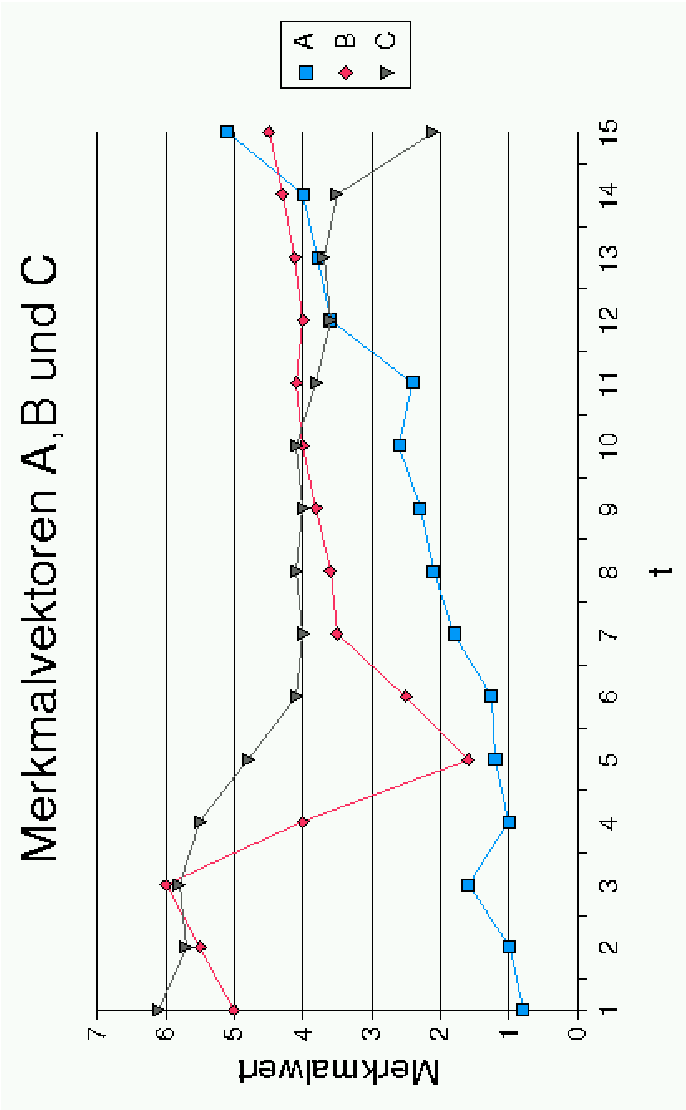
Merkmalvektoren A, B und C
Merkmalwert
t
A
B
C

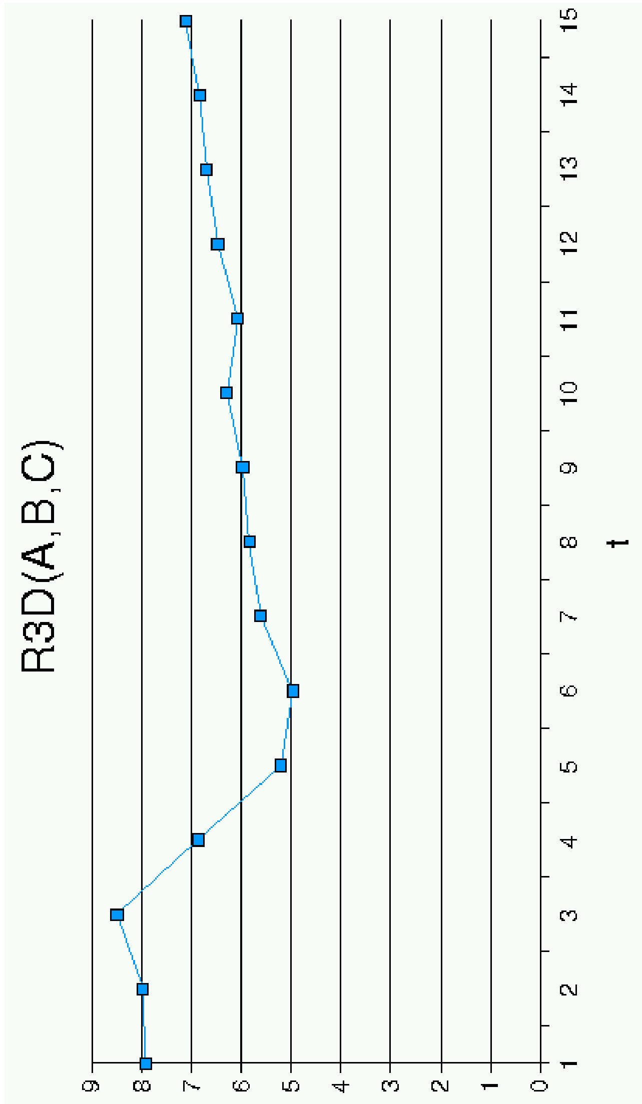
R3D(A,B,C)
t

Merkmaltransformationsfunktionen IV

Diskrete Fouriertransformation für $\overline{p}$ mit N gerade(vgl. [Bracewell, 1965]):

$$\mathrm{dft}(\overline{p}, \nu) = \frac{1}{N} \sum_{\tau=1}^{N} e^{-j2\pi(\frac{\nu}{N})\tau} p_\tau$$

- $\mathrm{dft}(\overline{p}, \nu)$ ist eine Funktion über ν mit Periode N.
- Da $\overline{\mathrm{dft}(\overline{p}, \nu)} = \mathrm{dft}(\overline{p}, -\nu) = \mathrm{dft}(\overline{p}, N - \nu)$ ist, gibt es zu $N/2 - 1$ Ausgabewerten konjugiert komplexe Ausgabewerten. Somit erhalten wir $N/2$ unterschiedliche Amplituden.

Die Funktion $F(\overline{p})$ liefert für $\overline{p} \in \Re^{15}$ mit $N = 16$ einen Amplitudenvektor $\overline{s} \in \Re^{8}$ zurück:

$$F(\overline{p}) = \overline{s} \Leftrightarrow s_\nu = \|\mathrm{dft}((\overline{p}, p_{15}), \nu)\|\,, \quad \text{für } \nu = 1, \ldots, 8 \tag{6}$$

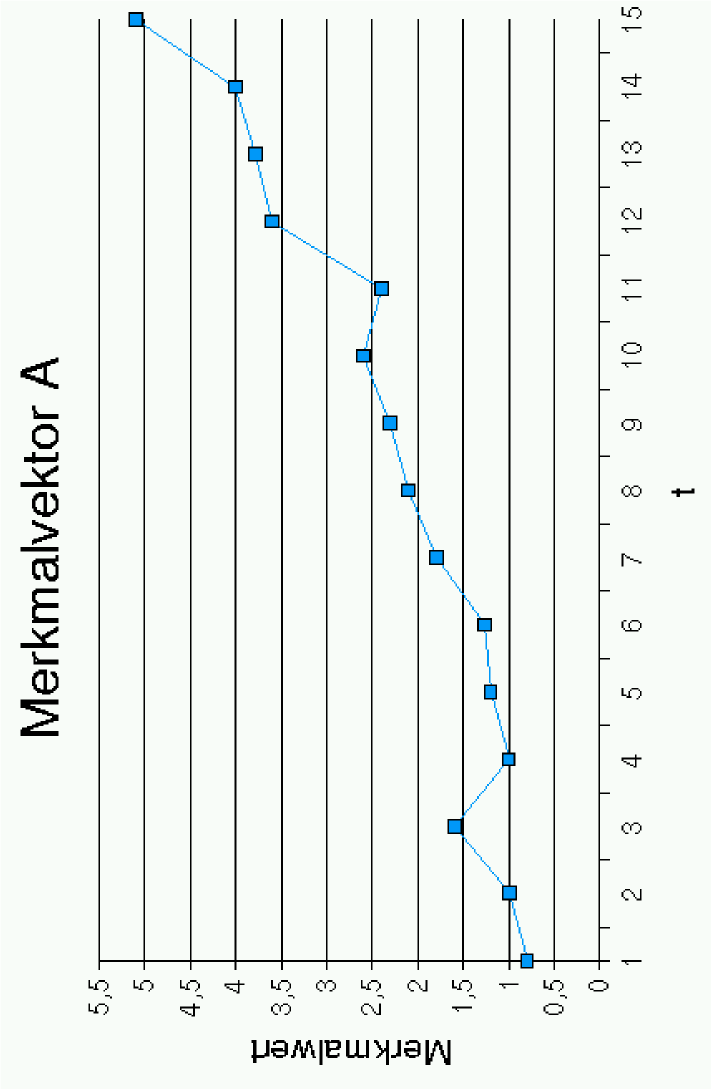
Merkmalvektor A
Merkmalwert
t
5,5
5
4,5
4
3,5
3
2,5
2
1,5
1
0,5
0
1
2
3
4
5
6
7
8
9
10
11
12
13
14
15

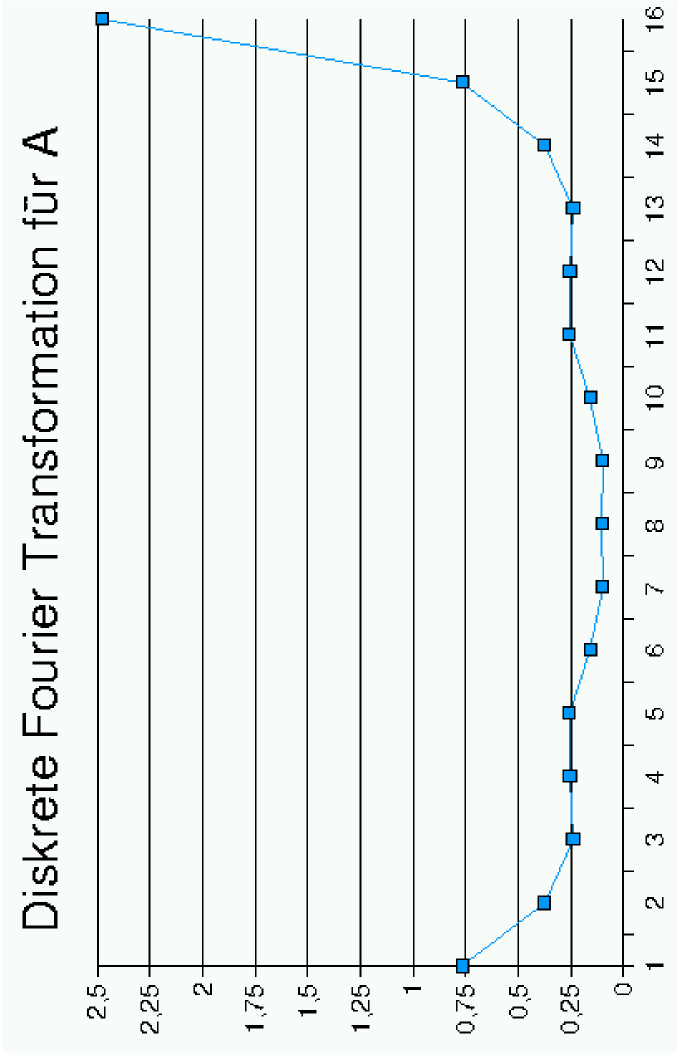
Diskrete Fourier Transformation für A
2,5
2,25
2
1,75
1,5
1,25
1
0,75
0,5
0,25
0
1
2
3
4
5
6
7
8
9
10
11
12
13
14
15
16

Merkmaltransformationsstrategie
S1: Raw Features

- Die Merkmalvektoren der Kräfte und Drehmomente im Überwachungsfenster bilden direkt die neuen Merkmale.
- Keine Merkmaltransformation!
- Anzahl Merkmale: $6 \cdot 15 = 90$

$$S1 \equiv (\bar{f}_x, \bar{f}_y, \bar{f}_z, \bar{t}_x, \bar{t}_y, \bar{t}_z)$$

Strategie 2 (S2): Resulting Forces and Torques

- Wir betrachten die ursprünglichen Merkmalvektoren und ergänzen diese um die Kombinationen der Kräfte und Drehmomente in der Ebene (siehe Formel (4)) und im Raum (siehe Formel (5)).
- Anzahl Merkmale: $(6+8) \cdot 15 = 210$

$$
\begin{aligned}
\bar{f}_{xy} &= R_{2D}(\bar{f}_x, \bar{f}_y) & \qquad \bar{t}_{xy} &= R_{2D}(\bar{t}_x, \bar{t}_y) \\
\bar{f}_{xz} &= R_{2D}(\bar{f}_x, \bar{f}_z) & \qquad \bar{t}_{xz} &= R_{2D}(\bar{t}_x, \bar{t}_z) \\
\bar{f}_{yz} &= R_{2D}(\bar{f}_y, \bar{f}_z) & \qquad \bar{t}_{yz} &= R_{2D}(\bar{t}_y, \bar{t}_z) \\
\bar{f}_{xyz} &= R_{3D}(\bar{f}_x, \bar{f}_y, \bar{f}_z) & \qquad \bar{t}_{xyz} &= R_{3D}(\bar{t}_x, \bar{t}_y, \bar{t}_z)
\end{aligned}
$$

$$
S2 \quad \equiv \quad (\bar{f}_x, \bar{f}_y, \bar{f}_z, \bar{f}_{xy}, \bar{f}_{xz}, \bar{f}_{yz}, \bar{f}_{xyz}, \bar{t}_x, \bar{t}_y, \bar{t}_z, \bar{t}_{xy}, \bar{t}_{xz}, \bar{t}_{yz}, \bar{t}_{xyz})
$$

Strategie 3(S3): Summary Features

- Generierung der neuen Merkmale durch Bestimmung des Durchschnitts A(Def. in (1)), der Durchschnittsveränderung D(Def. in (2)) und der Monotonie M(Def. in (3)) für die 6 Kraft- und Drehmomentvektoren.
- Anzahl Merkmale: $6 \cdot (9+3) = 72$

$$
\begin{aligned}
averages(\overline{p}) &= (\overbrace{A(\overline{p},1,3), A(\overline{p},4,6), A(\overline{p},7,9), A(\overline{p},10,12), A(\overline{p},13,15),}^{\text{Koernung } 3} \\
&\quad \underbrace{A(\overline{p},1,5), A(\overline{p},6,10), A(\overline{p},11,15),}_{\text{Koernung } 5} \ \underbrace{A(\overline{p},1,15)}_{\text{Koernung } 15} \ ) \\
S(\overline{p}) &= (averages(\overline{p}), D(\overline{p},1,8), D(\overline{p},8,15), M(\overline{p})) \qquad (7) \\
S3 &\equiv (S(\overline{f}_x), S(\overline{f}_y), S(\overline{f}_z), S(\overline{t}_x), S(\overline{t}_y), S(\overline{t}_z))
\end{aligned}
$$

Strategie 4(S4): Fourier Features

- Betrachtung der Merkmale, die sich durch die diskrete Fouriertransformation ergeben.
- Anzahl Merkmale: $6 \cdot 8 = 48$
- $F(\overline{p}) \in \mathfrak{R}^8$ definiert in (6).

$$S4 \quad \equiv \quad (F(\overline{f}_x), F(\overline{f}_y), F(\overline{f}_z), F(\overline{t}_x), F(\overline{t}_y), F(\overline{t}_z))$$

Strategie 5(S5): All Features

- Betrachtung aller Merkmale, die in den vorherigen Strategien einzeln untersucht wurden.
- Anzahl Merkmale: $14 \cdot (15 + 12 + 8) = 490$

$$B(\overline{p}) = (\overline{p}, S(\overline{p}), F(\overline{p}))$$

$$\begin{aligned} S2 \quad \equiv \quad & (B(\overline{f}_x), B(\overline{f}_y), B(\overline{f}_z), B(\overline{f}_{xy}), B(\overline{f}_{xz}), B(\overline{f}_{yz}), B(\overline{f}_{xyz}), \\ & B(\overline{t}_x), B(\overline{t}_y), B(\overline{t}_z), B(\overline{t}_{xy}), B(\overline{t}_{xz}), B(\overline{t}_{yz}), B(\overline{t}_{xyz})) \end{aligned}$$

Betrachtete Lernprobleme I

Wir betrachten 5 Lernprobleme (LP-1 bis LP-5), die für unterschiedliche Teilbereiche der Pick-and-Place-Operation unterschiedliche Fehlerklassifikationen lernen sollen.

LP-1:

- Fehler in *approach-grasp*
- Klassifikation: normal, collision, front collision und obstruction
- 88 Trainingsbeispiele

LP-2:

- Fehler in *transfer*
- Klassifikation: normal, front collision, back collision, collision to the right und collision to the left
- 47 Trainingsbeispiele

Betrachtete Lernprobleme II

LP-3:

- Fehler in *transfer*
- Klassifikation: ok, slighly moved, moved und lost
- 47 Trainingsbeispiele

LP-4:

- Fehler in *approach-ungrasp*
- Klassifikation: normal, collision und obstruction
- 117 Trainingsbeispiele

LP-5:

- Fehler in der Bewegung mit einem Teil
- Klassifikation: normal, bottom collision, bottom obstruction, collision in part und collision in tool
- 164 $(= 117 + 47)$ Trainingsbeispiele

Classification accuracy

Lernprobleme	S1	S2	S3	S4	S5
LP-1(*approach-grasp*:4)	78	80	96	85	89
LP-2(*transfer*:5)	45	57	51	68	64
LP-3(*transfer*:4)	49	75	87	85	83
LP-4(*approach-ungrasp*:3)	65	60	95	77	83
LP-5(Bewegung:5)	69	63	72	49	77
Durchschnitt	61	67	80	73	79

Auswertung Classification accuracy

- Die Merkmaltransformationstrategien führen zu einer Verbesserung der accuracy z.B.
  - Bei Problem LP-1(LP-3,LP-4) und Strategie S3 erhalten wir eine Verbesserung um $+18(+38, +30)$%.
- Strategie S2 (Kräfte- und Drehmomentkombinationen) liefert nur eine geringe Verbesserung in der accuracy.
- Die Lernproblem LP-2 und LP-5 sind sehr schwer.
- Obwohl Strategie 3 im Durchschnitt knapp besser bewertet wird als Strategie 5 gilt im allgemeinen: je mehr Merkmale den Lernverfahren zu Verfügung gestellt werden, umso wahrscheinlicher ist ein gutes Ergebnis.

Größe der Knotenmenge des Entscheidungsbaumes

Lernprobleme	S1	S2	S3	S4	S5
LP-1	9	9	6	9	8
LP-2	18	12	12	11	12
LP-3	14	10	6	10	8
LP-4	11	10	9	8	7
LP-5	28	26	14	20	11
Durchschnitt	16	13	9	12	9

Auswertung Größe des Entscheidungsbaumes

- Strategie 3 führt bei LP-3 zu einer Reduzierung der Baumgröße um mehr als die Hälfte ($14 \to 6$).
- Strategie 5 reduziert die Größe des Entscheidungsbaum für das sehr schwere Problem LP-5 von 28 auf 11 Knoten.

Vergleich zwischen SKIL und OC1

Approach	LP-1	LP-2	LP-3	LP-4	LP-5	Durchschnitt
OC1 (axis-parallel)	65	43	70	70	58	61
OC1 (oblique)	65	49	57	80	53	61
SKIL (no feature transf.)	78	45	49	65	69	61
SKIL (2nd best results)	89	64	85	83	72	79
SKIL (best results)	96	68	87	95	77	85

Auswertung Vergleich SKIL und OC1

- Ohne Merkmaltransformationen erhalten OC1 und SKIL im Durchschnitt den gleichen accuracy-Wert.
- Wird SKIL zusammen mit der Merkmaltransformation angewendet, verbessert sich die durchschnittliche accuracy beträchtlich.
- Zusätzlich zeigt ein Zeitvergleich, daß OC1 für das Lernen ca. 30 Stunden und SKIL 1 Stunde benötigt.

Ein weiteres Lernproblem

mit den folgenden zehn Klassifikationsattributen und den 88 Beispielen aus `approach_grasp` als Trainingsdaten :

1. *behavior* mit dem Wert normal oder failure.
   Aktiviert im Fall failure die Attribute *failure type*, *affected body*, *object size*, *object hardness* und *object weight*.
2. *phase* mit dem Wert initial, middle oder terminal.
3. *failure type* mit dem Wert collision, front collision oder obstruction.
4. *affected body* mit dem Wert tool, tool tubes oder fingers.
   Aktiviert im Fall tool das Attribut *tool region* und im Fall fingers das Attribut *fingers region*.
5. *tool region* mit dem Wert front, left, right, back und bottom.

Im Fall bottom wird das Attribut *bottom subregion* aktiviert.

6. *bottom subregion* mit dem Wert front, middle oder back.
7. *fingers region* mit dem Wert left finger, right finger and both fingers.
8. *object size* mit dem Wert small oder large.
9. *object hardness* mit dem Wert soft oder hard.
10. *object weight* mit dem Wert low oder high.

- Es sind nicht alle Attribute zur selben Zeit aktiviert.
- Maximal können 8 Vorhersagen in einem Begriff enthalten sein.
- Die durchschnittlich Größe des Begriffs in den Blättern der vollständigen Hierarchie ist 4.7.
- In diesem Problem soll gezeigt werden, daß die Merkmaltransformation sich auch auf die coverage des Begriffsraums positiv auswirkt.

$$\text{coverage} = \frac{\varnothing\text{Begriffsgröße in den Blättern der generierten Hierarchie}}{\varnothing\text{Begriffsgröße in den Blättern der vollständigen Hierarchie}}$$

- Die coverage zeigt an, ob die Trainingsdaten ausreichend Informationen enthalten haben.

Ergebnisse des weiteren Lernproblems

	S1	S2	S3	S4	S5
Experimental accuracy (%)	82	85	90	87	92
Coverage (%)	46	59	52	66	66
Size (nodes)	18	25	21	19	22

Zusammenfassung

- Wir benutzten vordefinierte Merkmaltransformationsstrategie, die genau für diese Anwendung entwickelt wurden.
- Durch Merkmaltransformation konnten wir in einigen Fällen die accuracy um 30% steigern und die Größe des Entscheidungsbaumes um mehr als die Hälfte reduzieren.
- Wir haben hier nur eine Fallstudie betrachtet, die man nicht direkt verallgemeinern kann.
- Die Merkmaltransformation ist stark vom Bereich abhängig und kann nicht direkt übertragen werden.
- Ein Ziel für die Zukunft ist die Identifikation von Objektklassen und zugehörigen Merkmaltransformationsstrategien auf diesen Objekten.

Literatur

[Bracewell, 1965] Bracewell, R. (1965). *The Fourier Transform and its Applications*. McGraw-Hill, Singapore.

[Seabra Lopes and Camarinha-Matos, 1998] Seabra Lopes, L. and Camarinha-Matos, L. M. (1998). Feature Transformation Strategies for a Robot Learning Problem. In Lin, H. and Motada, H., editors, *Feature Extraction Construction and Selection, A Date Mining Perspective*, chapter 23, pages 375–391. Kluwer Academic Publishers, Boston, Dordrecht, London.

[Seabra Lopes and Camarinha-Matos, 1999] Seabra Lopes, L. and Camarinha-Matos, L. M. (1999). Learning a Taxonomy of Failures in Assembly. In Morik, K., Klingspor, V., and Kaiser, M., editors, *Making Robots Smarter - Combining Sensing and Action through Robot Learning*, chapter 10, pages 161–184. Kluwer Academic Publishers, Boston, Dordrecht, London.