

# FuzzyART-basierte Ansätze für sensomotorische Problemstellungen

Marko Tscherepanow  
AG Angewandte Informatik  
Techn. Fakultät, Universität Bielefeld  
PSF 100131, D-33501 Bielefeld  
marko@techfak.uni-bielefeld.de

Andrea Scheidig  
FG Neuroinformatik & Kogn. Robotik  
Fakultät IA, TU Ilmenau  
PSF 100565, D-98684 Ilmenau  
andrea.scheidig@tu-ilmenau.de

## Zusammenfassung

*Im Rahmen sensomotorischer Aufgabenstellungen ist es häufig sinnvoll, sensorische Repräsentationen zu bilden, d.h., ähnliche sensorische Situationen zu Zuständen zusammenzufassen. Diese vereinfachte Darstellung der Umwelt ermöglicht dann eine Reduzierung des Berechnungsaufwands, der für weitere Verarbeitungsschritte, wie z.B. die Bestimmung geeigneter Aktionen, erforderlich ist. Durch die Bildung sensorischer Repräsentationen können jedoch auch Situationen zusammengefasst werden, die im Kontext der Aufgabe eines handlungsgenerierenden Systems eine unterschiedliche Bedeutung besitzen und deshalb verschiedene Aktionen des Systems erfordern. In diesem Artikel wird daher am Beispiel von FuzzyART ein Verfahren vorgestellt, das eine Berücksichtigung der Bedeutung sensorischer Situationen für die Handlungsauswahl schon bei der Bildung von Repräsentationen zulässt. Weiterhin erfolgt die Diskussion eines FuzzyART-basierten Ansatzes, der zusätzlich eine Begrenzung der benötigten Ressourcen in Form der erforderlichen Anzahl an Neuronen ermöglicht, wobei die Stabilitäts- und die Plastizitätseigenenschaft erhalten bleiben. Es wird gezeigt, dass beide Verfahren eine verbesserte Grundlage für das Erlernen und Anwenden von Verhaltenswissen bilden.*

## 1 Einleitung

Die Lösung sensomotorischer Problemstellungen setzt voraus, dass ein Agent seine aktuelle Situation hinreichend gut sensorisch erfasst. Daraus ergibt sich im Allgemeinen aber auch eine Vielzahl sensorischer Situationen, die für den Agenten dieselbe Bedeutung besitzen; beispielsweise existieren oftmals mehrere sensorische Situationen, denen die Bedeutung „Kollision“ oder „Freiraum“ zugeordnet werden kann. Eine Unterscheidung bedeutungsgleicher Situationen würde in Bezug auf die Lösung der Systemaufgabe in keinem Vorteil für den Agenten resultieren. Somit ist es sinnvoll, diese sensorischen Situationen mittels eines Clusterers zu sensorischen Zuständen zusammenzufassen. Nachteile hinsichtlich der Lösung der Systemaufgabe entstehen dadurch prinzipiell nicht. Für die Zusammenfassung sensorischer Situationen, d.h. die Repräsentation sensorischer Situationen

durch Zustände, sind z.B. neuronale Clusterer einsetzbar. Im Kontext einer sensomotorischen Problemstellung, wie der Navigation eines mobilen Systems in seiner Umwelt, ist zu beachten, dass sensorische Situationen aufgrund der darin auszuführenden motorischen Aktionen des Agenten zusätzlich mit Verhaltenswissen verknüpft werden. Dabei erfolgt eine Zuordnung von Verhaltenswissen zu den gebildeten Zuständen und nicht zu den ungeclusterten sensorischen Situationen. Somit ergibt sich die Forderung, dass eine einmal erlernte Abbildung einer sensorischen Situation auf einen Zustand trotz weiteren Trainings des Agenten und damit auch des Clusterers erhalten bleiben muss (*Stabilität*). Anderenfalls würde die Verknüpfung mit dem zugehörigen Verhaltenswissen verloren gehen. Gleichzeitig soll es dem Agenten aber möglich sein, neue sensorische Repräsentationen und Verhaltensweisen zu erlernen (*Plastizität*). Dies resultiert in der Notwendigkeit zur Entschärfung des *Stabilitäts-Plastizitäts-Dilemmas* [14].

Neuronale Clusterer, wie z.B. die Self-Organizing Feature Maps [8] oder das Neural Gas [9], approximieren die Inputdatenverteilung auf der Basis einer vorgegebenen Neuronenanzahl. Sie sind nicht in der Lage, stabile Repräsentationen sensorischer Situationen sicherzustellen und gleichzeitig neue sensorische Situationen zu erlernen. Vielmehr führen Veränderungen der Inputdatenverteilung bzw. der Verteilung sensorischer Situationen zu Veränderungen der Abbildung sensorischer Situationen auf Zustände. Somit ist es möglich, dass bekannte sensorische Situationen aufgrund des Lernvorgangs durch neue Zustände repräsentiert werden und damit bereits erworbenes Verhaltenswissen verloren geht.

Um das *Stabilitäts-Plastizitäts-Dilemma* zu entschärfen, ist daher der Einsatz inkrementeller Verfahren sinnvoll. Hierbei ist es jedoch erforderlich, dass ein Entfernen von Neuronen während des Trainings, wie z.B. beim Growing Neural Gas [5], ausgeschlossen wird, da ansonsten das korrespondierende Verhaltenswissen für den Agenten nicht mehr verfügbar wäre. Systeme der Adaptiven Resonanz Theorie (ART) [6] können diese Forderung erfüllen. Die ART-Neuronen sind hierbei als Repräsentationen sensorischer Situationen nutzbar. Ihre Gewichte bilden Unterräume im sensorischen Inputraum, die sich im Rahmen des Trainings nur vergrößern können. Diese Unterräume werden als Kategorien bezeichnet. Kann kein vorhandenes Neuron den aktuellen Input repräsentieren, wird ein neues Neuron eingefügt, das dazu in der Lage ist. Dadurch wird theoretisch sichergestellt, dass einmal erlernte Abbildungen sensorischer Situationen auf Zustände erhalten bleiben. Ein weiterer Vorteil von ART-Systemen ist der *Fast-Learning-Mode*, der eine vollständige Repräsentation präsentierter sensorischer Situationen schon nach einem einzigen Trainingsschritt zulässt. ART-Systeme bilden deshalb prinzipiell eine geeignete Basis für die Lösung sensomotorischer Aufgabenstellungen. Ihre Funktionsweise wird in Abschnitt 2 am Beispiel von FuzzyART [4] vorgestellt.

Trotz dieser vorteilhaften Eigenschaften von ART-Systemen bleibt ein wesentliches Problem bei der Bildung sensorischer Repräsentationen im Kontext sensomotorischer Problemstellungen bestehen – die Repräsentationsbildung erfolgt auf alleiniger Basis der Inputdatenverteilung, d.h. rein datengetrieben. Dadurch wird eine mögliche Bedeutung der Daten für einen Agenten vernachlässigt. Diese Bedeutung ergibt sich aus der Aufgabe eines Systems. Im Rahmen einer Navigationsaufgabe könnten z.B. Kollisionssituationen oder die Wahrnehmung bestimmter sensorischer Markierungen eine besondere Bedeutung besitzen. Typischerweise ist die Bedeutung der Inputdaten einem unüberwachten neuronalen Clusterer unbekannt. Es wird vielmehr implizit angenommen, dass Daten, die entsprechend einem definierten Ähnlichkeitsmaß (z.B. euklidischer Abstand beim Neural Gas [9]) einen geringen Abstand aufweisen, eine ähnliche Bedeutung besitzen. Diese Annahme ist jedoch oftmals nicht zutreffend, wenn sich die Bedeutung der Inputdaten aus einer anderen Quelle ergibt als die Inputs selbst. Ein Beispiel hierfür ist die Navigation eines mobilen Systems in einem Labyrinth aufgrund visueller Informationen, wobei das Kollisions- oder Reinforcementsignal aber anhand alternativer Daten, z.B. von Infrarotsensoren, ermittelt wird. Ein unüberwachter neuronaler Clusterer und somit auch ein ART-System ist dann nicht dazu in der Lage, die Bedeutung der Inputdaten zu repräsentieren. Dadurch findet unter Umständen eine Zusammenfassung sensorischer Situationen zu einem Zustand statt, die

im Kontext der Systemaufgabe eine unterschiedliche Bedeutung besitzen und deshalb verschiedene Aktionen erfordern. Die Wahl einer entsprechend der Systemaufgabe sinnvollen Aktion, beispielsweise die Entfernung von einem Hindernis im Rahmen einer Kollisionsvermeidung, wird damit erschwert oder unmöglich. Um dieses Problem zu vermeiden, ist eine bedeutungsorientierte Steuerung der Repräsentationsbildung notwendig. In Abschnitt 3 wird daher am Beispiel von FuzzyART ein Verfahren vorgestellt, das solch eine Integration der Bedeutung von Inputdaten in die Clusterung zulässt.

Ein weiteres Problem der Bildung sensorischer Repräsentationen unter Nutzung inkrementeller neuronaler Clusterer ergibt sich aus der Beschränkung der Ressourcen (Speicher, Rechenzeit bzw. Neuronenzahl), wodurch ein unbegrenztes Wachstum der Netzwerke unmöglich ist. Damit können auch inkrementelle ART-Systeme gegebenenfalls nur eine begrenzte Anzahl sensorischer Situationen repräsentieren, d.h., das System verliert seine Plastizitätseigenschaft, wenn die Ressourcen aufgebraucht sind. Um dieses Problem zu entschärfen, wird in Abschnitt 4 am Beispiel von FuzzyART eine Methode vorgestellt, die eine Reduzierung der Anzahl benötigter Neuronen realisiert und damit die Menge genutzter Ressourcen verringert. Die Stabilitäts- und die Plastizitätseigenschaft von FuzzyART bleiben dabei erhalten.

In Abschnitt 5 findet eine Betrachtung beider vorgestellten Verfahren im Kontext einer Kollisionsvermeidung durch den Miniaturroboter KHEPERA [7] statt. Dabei werden die Vorteile beider Ansätze bezüglich der Bildung sensomotorischer Repräsentationen deutlich gemacht. Abschließend erfolgt in Abschnitt 6 ein kurzer Ausblick und die Diskussion weiterer Einsatzmöglichkeiten.

## 2 FuzzyART

ART-Systeme [6] besitzen eine inkrementelle Architektur mit drei Schichten von Neuronen: Vorverarbeitungsschicht  $F0$ , Vergleichsschicht  $F1$  und Erkennungsschicht  $F2$ . Die prinzipielle Architektur kann bei verschiedenen ART-Systemen leicht variieren. Insbesondere die Gewichte können abhängig von der Form der Kategorien unterschiedliche Informationen kodieren. Die Gewichte von FuzzyART [4] und DistributedART [1] kodieren beispielsweise Hyperrechtecke im Inputraum, wogegen die Kategorien von GaußART [13] multivariaten Gaußverteilungen unabhängiger Zufallsvariablen entsprechen. Bei der Wahl eines geeigneten ART-Systems für die Lösung einer sensomotorischen Aufgabenstellung ist zu beachten, dass nicht alle ART-Systeme gleichermaßen geeignet sind. So ermöglicht GaußART aufgrund des genutzten Lernverfahrens keine stabile Repräsentation sensorischer Situationen [11]. FuzzyART [4] hingegen, ist hierzu grundsätzlich in der Lage. Da die FuzzyART-Kategorien die Form von Hyperrechtecken besitzen, erfolgt die Bildung von Repräsentationen mittels einfacher und deshalb schneller Rechenoperationen. Aufgrund der Stabilität der gebildeten Repräsentationen, der einfachen Berechenbarkeit sowie der anschaulichen Interpretierbarkeit der Kategorien, ist FuzzyART ein ART-System, das als Basis für die Lösung sensomotorischer Problemstellungen prinzipiell gut geeignet ist. Daher wird FuzzyART im Folgenden detaillierter betrachtet, um die selbst vorgenommenen Modifikationen (siehe Abschnitte 3 und 4) erklären zu können. Der vollständige Algorithmus ist in [4] zu finden.

Um das Neuron zu ermitteln, das eine dem FuzzyART präsentierte sensorische Situation repräsentiert, wird zunächst in der Erkennungsschicht  $F2$  auf der Grundlage des vorverarbeiteten Inputs  $\underline{y}^{F0}(t) = f(\underline{x}(t))$  eine mögliche Repräsentation bzw. Erwartung  $\underline{y}^{F2}(t)$  gebildet. Dazu erfolgt die Berechnung der Aktivierungen  $z_j^{F2}(t)$  (choice function) aller  $N$   $F2$ -Neuronen  $j$  nach Gleichung 1, wobei  $\underline{w}_j^{F2-F1}(t)$  die Gewichte der Verbindungen des jeweiligen Neurons zur  $F1$ -Schicht bezeichnet. „ $\wedge$ “ symbolisiert den Fuzzy-AND Operator entsprechend [4]. Der Auswahlparameter  $\alpha$  steuert zusätzlich die Neuronenaktivierungen in Abhängigkeit der Kategoriegröße [13].

$$z_j^{F2}(t) = \frac{|\underline{y}^{F0}(t) \wedge \underline{w}_j^{F2-F1}(t)|}{\alpha + |\underline{w}_j^{F2-F1}(t)|} \quad \text{mit} \quad \alpha \geq 0 \quad (1)$$

Nach der Ermittlung der  $F2$ -Aktivierungen kann für jedes Neuron  $j$  der  $F2$ -Schicht die Erwartung bzw. Ausgabe  $y_j^{F2}(t)$  bestimmt werden. Das maximal aktivierte Neuron  $b$  erhält die Ausgabe  $y_b^{F2}(t) = 1$  und alle anderen Neuronen die Ausgabe 0. Die so gebildete Erwartung  $\underline{y}^{F2}(t)$  wird in der  $F1$ -Schicht mit dem vorverarbeiteten Input  $\underline{y}^{F0}(t)$  verglichen. Als Vergleichskriterium dient das in Ungleichung 2 dargestellte *Vigilancekriterium* (match function).

$$\frac{|\underline{y}^{F0}(t) \wedge \underline{w}_b^{F2-F1}(t)|}{\underline{y}^{F0}(t)} \geq \rho \quad \text{mit} \quad \rho \in [0, 1] \quad (2)$$

Die Vigilance  $\rho$  ist ein Maß für die minimale Genauigkeit, mit der ein Input  $\underline{x}(t)$  durch ein Best-Matching-Neuron repräsentierbar sein muss, damit dieses Neuron als Repräsentation genutzt werden darf. Die maximale Größe der Kategorien ist dabei umgekehrt proportional zur gewählten Vigilance. Eine Vigilance von 1 beschränkt die Hyperrechtecke auf einzelne Punkte im Inputraum, wogegen geringere Beträge von  $\rho$  ein verstärktes Wachstum der Kategorien zulassen.

Ist das Vigilancekriterium erfüllt, kann das entsprechende maximal aktivierte  $F2$ -Neuron  $b$  den Input repräsentieren, das System gelangt in den Resonanzzustand und die Gewichte des Best-Matching-Neurons  $b$  werden adaptiert. Anderenfalls erfolgt ein Reset der  $F2$ -Aktivierung von Neuron  $b$  und die Bildung einer neuen Erwartung. Kann kein vorhandenes  $F2$ -Neuron den aktuellen Input repräsentieren, wird ein neues  $F2$ -Neuron eingefügt. In Bezug auf die Gewichtsadaptation ist zu beachten, dass FuzzyART-Kategorien nur anwachsen können. Deshalb sind gelernte sensorische Situationen auch nach weiterem Training garantiert durch dasselbe Neuron repräsentierbar. Nachteilig ist dabei jedoch, dass als Folge des Lernprozesses verschiedene Neuronen gleiche Teilbereiche des Inputraums kodieren können (siehe Abbildung 1).

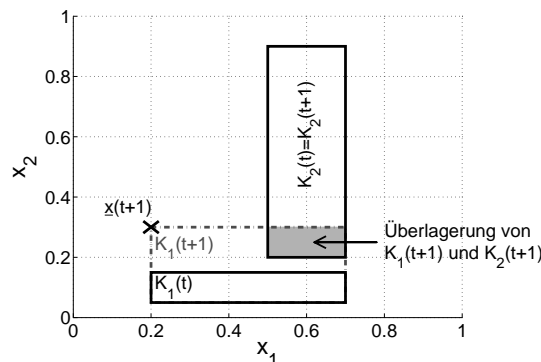


Abbildung 1. Überlagerung von FuzzyART-Kategorien. Ein FuzzyART-System mit zwei Neuronen repräsentiert Inputs aus einem zweidimensionalen Inputraum mit den Komponenten  $x_1$  und  $x_2$ . Die entsprechenden Kategorien werden hierbei als  $K_1(t)$  und  $K_2(t)$  bezeichnet. Zum Zeitpunkt  $t + 1$  wird dem Netz ein Input  $\underline{x}(t + 1)$  präsentiert, der in keiner der beiden Kategorien enthalten ist. Unter der Annahme, dass das Vigilancekriterium erfüllt wird, dehnt sich Kategorie  $K_1$  aus (unterbrochene Linie), da Neuron 1 die höchste Aktivierung besitzt. Nach dem Lernvorgang umfasst  $K_1$  jedoch auch einen Teilbereich von  $K_2$ .

In Bereichen des Inputraums, die von mehreren Neuronen repräsentiert werden, ist bei FuzzyART keine eindeutige Zuordnung von Inputs zu einem bestimmten Neuron realisierbar, da alle diese Neuronen entsprechend Gleichung 1 eine maximale Aktivierung besitzen. Deshalb kann in solchen Bereichen kein eindeutiges Best-Matching-Neuron ermittelt werden. Um dennoch eine Repräsentation bilden zu können, wird das Neuron mit dem geringsten Index gewählt [4]. Im Kontext einer sensomotorischen Aufgabenstellung ist es somit möglich, dass erworbenes Verhaltenswissen, das mit alternativen Best-Matching-Neuronen verknüpft ist, verloren geht, obwohl alle  $F2$ -Neuronen prinzipiell eine stabile Repräsentation sensorischer Situationen ermöglichen.

### 3 Bedeutungsorientierte Repräsentationsbildung

In diesem Abschnitt wird ein Verfahren zur bedeutungsorientierten Bildung sensorischer Repräsentationen am Beispiel von FuzzyART vorgestellt. Um die Bedeutung von Inputdaten in die Repräsentationsbildung integrieren zu können, ist zunächst ihre Quantifizierung erforderlich. Diese Quantifizierung kann durch eine Bewertungsfunktion  $\Psi(\underline{x}(t))$  erfolgen, die jedem Input  $\underline{x}(t)$  entsprechend seiner Bedeutung einen Wert aus dem Intervall  $[0, 1]$  zuordnet. Die so gebildeten Bewertungen von Inputdaten sind direkt für die Steuerung der Repräsentationsbildung nutzbar (*Bewertungssteuerung*). Als Basis für die Entwicklung einer Bewertungssteuerung können sowohl unüberwachte, als auch überwachte neuronale Clusterer dienen. Die Bewertung der Inputdaten ist dabei funktionell mit dem Teacher bzw. der Klassenzugehörigkeit bei überwachten neuronalen Clusterern, wie z.B. ARTMAP [3], vergleichbar. Solche überwachten Verfahren lernen Abbildungen von Inputs auf Teacherdaten, indem nur eine Zusammenfassung ähnlicher Inputs zu Clustern stattfindet, wenn diese derselben Klasse angehören. Die gebildeten Cluster werden in einem weiteren Verarbeitungsschritt Klassen zugeordnet. Auf der Grundlage der gelernten Cluster bzw. Repräsentationen kann dann für unbekannte Inputs eine Klassenzuordnung erfolgen. Eine Bewertungssteuerung arbeitet teilweise analog dazu, da ein Cluster auch hierbei nur Inputs mit ähnlichen Bewertungen umfassen darf. Im Gegensatz zu überwachten Clusterern erfolgt bei einer Bewertungssteuerung jedoch keine Zuordnung von Bewertungen zu unbekanntem Inputs.

Eine Bewertungssteuerung kann daher auch auf der Basis unüberwachter neuronaler Clusterer realisiert werden, indem trainingsrelevante Parameter, wie Lernrate oder Vigilance, mit der Bewertung verknüpft werden. In [12] wird z.B. ein Verfahren beschrieben, das die Steuerung eines unüberwachten Neural Gas Netzes ermöglicht. Als Bedeutung dient hierbei die Verteilungsdichte der Inputdaten. Die entsprechenden Bewertungen werden so in den Lernprozess integriert, dass eine gezielte Steuerung der Verteilung der Gewichtsvektoren in Abhängigkeit von der Inputdatenverteilung realisierbar ist. Somit ist u.a. eine detailliertere Repräsentation seltener, aber für die Systemaufgabe dennoch bedeutender sensorischer Situationen möglich. Dabei ist zu beachten, dass bei diesem Ansatz die Bewertung nicht explizit vorgegeben werden muss, sondern anhand der präsentierten Inputs bestimmt wird.

Die Integration einer Bewertungssteuerung in unüberwachte neuronale Clusterer bietet gegenüber der Verwendung überwachter Verfahren den Vorteil, auf Strukturen, die ausschließlich zur Approximation der Teacherdaten dienen, verzichten zu können. Dies wird auch am Beispiel des überwachten Pendants von ART, ARTMAP [3], deutlich. Hierbei werden zwei ART-Systeme  $ART_a$  und  $ART_b$  über ein Inter-ART-Modul, das Map-Feld, miteinander verbunden.  $ART_a$  clustert die Inputs und  $ART_b$  die Teacherdaten. Im Map-Feld werden Assoziationen zwischen den Kategorien beider Systeme gebildet. Falls im Map-Feld Unterschiede in der Kategorisierung von  $ART_a$  und  $ART_b$  auftreten, wird die Vigilance von  $ART_a$  soweit erhöht, dass ein Reset erfolgt. Damit wird sichergestellt, dass Kategorien von  $ART_a$  nur Inputs repräsentieren, die denselben Kategorien von  $ART_b$  entsprechen und damit auf dieselben Teacherdaten abgebildet werden.

Eine direkte Integration einer Bewertungssteuerung in den unüberwachten Lernprozess von ART ist jedoch vorteilhafter, da hierbei:

1. das Map-Feld und  $ART_b$  nicht erforderlich sind, womit der Verbrauch an Rechenzeit und Ressourcen verringert wird,
2. die Bewertungen direkt und nicht in Form von Repräsentationen des Systems  $ART_b$  genutzt werden können und
3. das Verfahren überschaubarer und somit einfacher an spezifische Problemstellungen anpassbar ist.

Aufgrund dieser Vorteile integrierten wir eine Bewertungssteuerung in FuzzyART als Alternative zur ebenfalls denkbaren Nutzung von FuzzyARTMAP. Das entsprechende Verfahren wird in Abschnitt 3.1 vorgestellt. In Abschnitt 3.2 erfolgt dann anhand ausgewählter künstlicher Datenverteilungen ein Vergleich der gebildeten Repräsentationen mit einem originalen FuzzyART und einem für die Bewertungssteuerung genutzten FuzzyARTMAP, um den Nutzen einer Bewertungssteuerung deutlich zu machen. Zusätzlich wird dabei auch ein weiterer Vorteil der direkten Integration einer Bewertungssteuerung in FuzzyART im Vergleich zur Verwendung von FuzzyARTMAP sichtbar – eine geringere Anzahl erforderlicher Neuronen.

### 3.1 Bewertungssteuerung von FuzzyART

Bei ART-Systemen wird anhand des Vigilancekriteriums (siehe Ungleichung 2) bestimmt, ob eine Kategorie in der Lage ist, einen spezifischen Input zu repräsentieren. Um eine Berücksichtigung der Bewertung von Inputdaten bei der Bildung sensorischer Repräsentationen zu realisieren, muss folglich das Vigilancekriterium angepasst werden. Eine Möglichkeit dazu stellt die Substitution der ursprünglichen Vigilance  $\rho$  durch eine vom jeweiligen Best-Matching-Neuron  $b$  und dem aktuellen Input  $\underline{x}(t)$  abhängige Vigilance  $\rho_b(t)$  dar (siehe Gleichung 3) [10, 11].

$$\rho_b(t) = \underbrace{\rho}_{(i)} + \underbrace{(1 - \rho)}_{(ii)} \cdot \underbrace{\left| \psi_b - \Psi(\underline{x}(t)) \right|^n}_{(iii)} \quad \text{mit} \quad 0 \leq \Psi(\underline{x}(t)) \leq 1; \quad 0 < n \leq 1 \quad (3)$$

Um eine Vergleichbarkeit mit dem originalen FuzzyART zu ermöglichen, wurde die ursprüngliche Vigilance  $\rho$  als Basisvigilance beibehalten (siehe Term (i) in Gleichung 3). Ihr Wert wird von  $\rho_b(t)$  nicht unterschritten. Deshalb können die Kategorien eines bewertungsgesteuerten sowie eines originalen Systems mit gleicher Vigilance bzw. Basisvigilance prinzipiell auf dieselbe maximale Größe anwachsen. Die modifizierte Vigilance ist damit auf Beträge aus dem Intervall  $(\rho, 1]$  beschränkt, wodurch sich Term (ii) in Gleichung 3 ergibt. Um den Unterschied der Bewertungen von Inputs, die durch eine Kategorie repräsentiert werden, zum aktuellen Input ermitteln zu können, erhält jedes  $F^2$ -Neuron  $j$  eine Bewertung  $\psi_j$ . Die Bestimmung der Bewertung des aktuellen Inputs  $\underline{x}(t)$  erfolgt entsprechend einer Bewertungsfunktion  $\Psi(\underline{x}(t))$ , die die Bedeutung von  $\underline{x}(t)$  im Kontext der Systemaufgabe quantifiziert. Unterscheiden sich  $\psi_b$  und  $\Psi(\underline{x}(t))$  (siehe Term (iii) in Gleichung 3) wird die Vigilance  $\rho_b(t)$  erhöht und somit die maximale Größe der Kategorie des Best-Matching-Neurons  $b$  verringert. Demzufolge wird die Fähigkeit von Neuron  $b$ , den jeweiligen Input zu repräsentieren, eingeschränkt. Der Parameter  $n$  steuert hierbei die Stärke der Vigilanceerhöhung in Abhängigkeit der Betragsdifferenz von  $\psi_b$  und  $\Psi(\underline{x}(t))$ . Ist  $n < 1$ , führen schon geringere Unterschiede der Bewertungen zu einem stärkeren Anstieg von  $\rho_b(t)$  und damit zu einer stärkeren Einschränkung der Fähigkeit von Neuron  $b$  den jeweiligen Input zu repräsentieren. Die Bestimmung von  $n$  kann entsprechend Gleichung 3 erfolgen, indem eine Betragsdifferenz von  $\psi_b$  und  $\Psi(\underline{x}(t))$  vorgegeben wird, für die  $\rho_b(t)$  bei einer spezifischen Basisvigilance  $\rho$  einen definierten Wert erreichen soll.

Um die Stabilität der gebildeten Kategorien zu gewährleisten, ist es erforderlich, dass die Vigilance  $\rho_b(t)$  für gleiche Inputs während des gesamten Lernvorgangs konstant bleibt. Diese Forderung wird z.B. erfüllt, wenn die Bewertung des ersten Inputs, den ein Neuron  $j$  erlernt, mit der Bewertung  $\psi_j$  gleichgesetzt wird [11].

Da die Aktivierung der Neuronen (siehe Gleichung 1) unabhängig von den Bewertungen  $\psi_j$  und  $\Psi(\underline{x}(t))$  erfolgt, werden nach der Präsentation eines Inputs  $\underline{x}(t)$  alle Neuronen, die ähnliche Inputs kodieren, stark aktiviert. Dies schließt auch Neuronen ein, die eine abweichende Bewertung  $\psi_j$  besitzen und daher das modifizierte Vigilancekriterium (siehe Gleichung 3) nicht oder nur suboptimal erfüllen. Dabei bedeutet „suboptimal“, dass das modifizierte Vigilancekriterium zwar erfüllt wird, aber alternative Neuronen vorhanden sind, die die Bedeutung des Inputs  $\underline{x}(t)$  besser repräsentieren

können und ebenfalls in der Lage sind,  $\underline{x}(t)$  zu erlernen. Um dieses Problem zu umgehen, ist es sinnvoll, zusätzlich die Berechnung der Aktivierungen der  $F^2$ -Neuronen in Abhängigkeit von der Bewertung der Inputdaten zu steuern [10]. Hierbei sollte die entsprechend modifizierte Aktivierung  $\tilde{z}_j^{F^2}(t)$  eines  $F^2$ -Neurons  $j$  ausgehend von der ursprünglichen Aktivierung  $z_j^{F^2}(t)$  (siehe Gleichung 1) proportional zum Anstieg der Vigilance  $\rho_j(t)$  abfallen. Eine Möglichkeit dafür stellt Gleichung 4 dar.

$$\tilde{z}_j^{F^2}(t) = z_j^{F^2}(t) - z_j^{F^2}(t) \cdot \left| \psi_j - \Psi(\underline{x}(t)) \right|^n \quad (4)$$

Die Verwendung solch einer modifizierten Aktivierungsfunktion ermöglicht außerdem in Bereichen des Inputraumes, die von mehreren Neuronen repräsentiert werden (siehe Abbildung 1), eine stabilere Zuordnung von Inputs zu Kategorien, da die Bedeutung der Daten als zusätzliches Unterscheidungskriterium dient.

### 3.2 Repräsentationsbildung am Beispiel künstlicher Daten

Die Funktionsweise einer Bewertungssteuerung kann gut an dem bereits für die Untersuchung von FuzzyARTMAP genutzten CIRCLE-IN-THE-SQUARE Problem (CITS) [2] veranschaulicht werden. Dabei erfolgt eine Unterteilung des Inputraums in zwei durch einen Kreis getrennte Bereiche bzw. Klassen, die denselben Flächeninhalt besitzen. Um die gewonnenen Ergebnisse verifizieren zu können, wurden in den Experimenten zwei analoge Probleme mit alternativen geometrischen Figuren genutzt: SQUARE-IN-THE-SQUARE (SITS) sowie TRIANGLE-IN-THE-SQUARE (TITS). Im Gegensatz zu Untersuchungen überwachter neuronaler Clusterer diente hierbei nicht der Klassifikationsfehler als Vergleichskriterium, sondern das Ausmaß, in dem eine Kategorie die Bedeutung der in ihr enthaltenen Inputs widerspiegelt.

Im Rahmen der durchgeführten Untersuchungen wurde angenommen, dass jeweils beide Bereiche des Inputraums unterschiedliche Bedeutungen besitzen; Inputs innerhalb der inneren Figur erhielten daher die Bewertung  $\Psi(\underline{x}(t)) = 1$ , Inputs außerhalb die Bewertung  $\Psi(\underline{x}(t)) = 0$ .<sup>1</sup> Da somit auch die Differenz  $|\psi_j - \Psi(\underline{x}(t))|$  beim bewertungsgesteuerten FuzzyART (siehe Gleichungen 3 und 4) nur die diskreten Werte 0 und 1 annehmen kann, ist der Parameter  $n$  bedeutungslos. Das Training der betrachteten Verfahren – einem originalen FuzzyART, einem bewertungsgesteuerten FuzzyART sowie einem FuzzyARTMAP mit jeweils einer (Basis-)Vigilance von  $\rho = 0.8$  – erfolgte durch 100000-elementige Trainingsdatensätze mit zufällig ausgewählten Inputs entsprechend der Problemstellung im Fast-Learning-Mode. Für die graphische Darstellung wurden Testdatensätze genutzt, die  $101 \times 101$  äquidistant im Inputraum verteilte Inputs umfassten.

Nach dem Training der drei untersuchten Verfahren entsprechend einer der verwendeten Datenverteilungen fand für die Inputs jeweils beider Datensätze eine Bestimmung der Best-Matching-Neuronen statt. Anschließend wurde überprüft, ob die Kategorie des jeweiligen Best-Matching-Neurons die Bedeutung des aktuellen Inputs korrekt widerspiegelt.<sup>2</sup> Dazu erfolgte eine Approximation der Bedeutung der von diesem Neuron repräsentierten Inputs auf der Basis der vier Eckpunkte sowie des Mittelpunkts der Kategorie. Die Bewertung der Mehrzahl dieser Punkte wurde dabei als Bewertung und damit als Maß der Bedeutung der Kategorie interpretiert.

Im Ergebnis ist feststellbar, dass die Kategorien des originalen FuzzyART die Bedeutung der Inputs nur unzureichend repräsentierten. Die Bewertung der entsprechenden Kategorien der Best-Matching-Neuronen entsprach beim jeweiligen Trainingsdatensatz nur zu 88.59% (CITS), 80.15% (SITS) sowie 91.50% (TITS) und beim entsprechenden Testdatensatz nur zu 88.87% (CITS), 80.53% (SITS) sowie 91.44% (TITS) der Bewertung der Inputs. Das bewertungsgesteuerte FuzzyART und FuzzyARTMAP ermöglichten dagegen eine korrekte Repräsentation der Bedeutung aller Inputs (siehe Abbildung 2).

<sup>1</sup>Die Verwendung kontinuierlicher Bewertungen wäre ebenfalls möglich. Zugunsten der Anschaulichkeit der Experimente wurde aber darauf verzichtet.

<sup>2</sup>Bei FuzzyARTMAP wurde hierfür die Kategorie des Best-Matching-Neurons von  $ART_a$  verwendet.

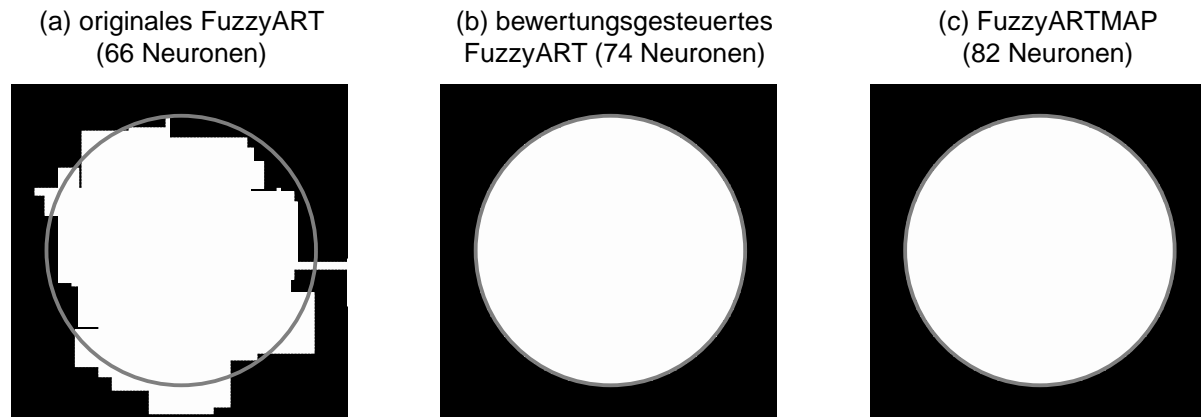


Abbildung 2. Repräsentation der Bedeutung von Inputdaten am Beispiel des CIRCLE-IN-THE-SQUARE Problems. Einem originalen FuzzyART (a), einem bewertungsgesteuerten FuzzyART (b) und einem FuzzyARTMAP (c) wurde der Testdatensatz präsentiert und die jeweiligen Best-Matching-Neuronen ermittelt. Auf der Basis der entsprechenden Kategorien erfolgte eine Approximation der Bewertung der von diesen Neuronen repräsentierten Inputs; Weiß entspricht einer Bewertung von 1 und Schwarz einer Bewertung von 0. Bei einer korrekten Repräsentation der Bedeutung sollten also alle Inputs innerhalb des grauen Kreises, der die Grenze der beiden Teilbereiche des Inputraums symbolisiert, weiß und außerhalb schwarz dargestellt werden. Dies geschieht jedoch nur beim bewertungsgesteuerten FuzzyART und beim FuzzyARTMAP. Das originale FuzzyART kann also die Bedeutung der Inputdaten nur eingeschränkt repräsentieren.

Anhand der drei untersuchten Datenverteilungen konnte somit gezeigt werden, dass sowohl das in Abschnitt 3.1 vorgestellte Verfahren zu Bewertungssteuerung von FuzzyART, als auch FuzzyARTMAP die Bedeutung von Inputdaten in die Clusterung einbeziehen. Damit ist eine bedeutungsabhängige Zusammenfassung sensorischer Situationen zu Zuständen realisierbar. Das originale FuzzyART berücksichtigt die Bedeutung der Inputdaten hingegen nur indirekt, soweit sie in den Inputs selbst erkennbar ist. Es ist daher für die Lösung sensomotorischer Aufgabenstellungen weniger gut geeignet.

Weiterhin benötigte das bewertungsgesteuerte FuzzyART im Vergleich zum FuzzyARTMAP, das jeweils ca. 85 Neuronen nutzte, eine um 9.76% (CITS), 9.64% (SITS) bzw. 5.81% (SITS) geringere Anzahl an Neuronen, obwohl dieselben Ergebnisse erzielt wurden. Die Ursache hierfür liegt in der bei FuzzyARTMAP im Rahmen der Bestimmung einer Repräsentation durchgeführten globalen, d.h. für alle Neuronen geltenden Erhöhung der Vigilance, die ausgelöst wird, falls ein Best-Matching-Neuron von  $ART_a$  die Bedeutung des aktuellen Inputs  $\underline{x}(t)$  nicht korrekt repräsentiert. Dadurch findet eine unnötige Einschränkung der Ausdehnung von Kategorien folgender Best-Matching-Neuronen für  $\underline{x}(t)$  statt, wodurch eine höhere Anzahl an Neuronen erforderlich ist. Das in Abschnitt 3.1 vorgestellte Verfahren berechnet hingegen für jedes Neuron bezüglich eines spezifischen Inputs eine eigene, lokale Vigilance. Eine Beeinflussung durch vorherige, bereits verworfene Best-Matching-Neuronen erfolgt nicht. Dies resultiert in einer effizienteren Repräsentation der gelernten Inputs und ihrer Bedeutung.

## 4 Repräsentationsbildung bei beschränkten Ressourcen

Ein weiteres wesentliches Problem der Bildung sensomotorischer Repräsentationen ist die Beschränkung der zur Verfügung stehenden technischen Ressourcen, wie z.B. der Speicherkapazität, durch die ein unbeschränktes Wachstum neuronaler Netze nicht realisierbar ist. Dabei müssen auch aufbauende Verarbeitungsschritte berücksichtigt werden. Die von uns untersuchte und für die Handlungsgenerierung genutzte Modellarchitektur [10] erfordert beispielsweise bei  $N$   $F2$ -Neuronen und



A ausführbaren Aktionen ein paralleles Training von  $2 \cdot A \cdot N^2$  weiteren Parametern (Gewichten). Insbesondere der Komplexität realer Agenten mit hochdimensionalen Inputvektoren sind damit Grenzen gesetzt. Auch ART-Systeme, die eine Lösung des Stabilitäts-Plastizitäts-Dilemmas darstellen, können nach Verbrauch aller Ressourcen, d.h. dem Erreichen einer maximal möglichen Neuronenzahl, keine Repräsentationen beliebiger neuer sensorischer Situationen erlernen. Inputs, die in keiner Kategorie enthalten sind, müssen dann beispielsweise durch das  $F2$ -Neuron mit der höchsten Aktivierung repräsentiert werden.

Um dieses Problem zu entschärfen, ist es sinnvoll, die Anzahl einzufügender Neuronen schon zu Beginn des Lernprozesses einzuschränken. Das ist z.B. erreichbar, indem angenommen wird, dass Neuronen mit einer um höchstens den Betrag  $\delta$  von der maximalen Aktivierung 1 abweichenden Aktivierung trotzdem in der Lage sind, den aktuellen Input hinreichend gut zu repräsentieren [10]. Neue Neuronen müssen dann nur eingefügt werden, falls kein Neuron eine Aktivierung höher als  $1 - \delta$  besitzt. Dadurch erfolgt eine deutliche Reduzierung der Anzahl benötigter  $F2$ -Neuronen, die insbesondere bei realen Agenten mit höherdimensionalen Inputräumen erforderlich ist. Tabelle 1 zeigt diese Verringerung am Beispiel eines 10052-elementigen Datensatzes mit 8-dimensionalen Inputs, die den Werten der Infrarotsensoren des Miniaturroboters KHEPERA bei zufälliger Bewegung in einem Versuchsszenario entsprechen.

	$\rho = 0.5$	$\rho = 0.6$	$\rho = 0.7$	$\rho = 0.8$	$\rho = 0.9$
$\delta = 0.0$	154	640	2400	5569	5915
$\delta = 0.025$	27	52	147	415	1298
$\delta = 0.05$	14	22	45	95	316
$\delta = 0.1$	5	10	14	24	49

Tabelle 1. Anzahl genutzter Neuronen. Eine Erhöhung des Parameters  $\delta$  resultiert in einer deutlichen Verringerung der Anzahl  $N$  genutzter  $F2$ -Neuronen. Für  $\delta = 0$  entspricht das System einem originalen FuzzyART.

Durch eine Verringerung der Vigilance  $\rho$  beim originalen FuzzyART ist solch eine Reduzierung der Neuronenzahl ebenfalls möglich. Es entstehen jedoch unerwünschte Überlagerungen von Kategorien, da diese durch eine geringere Vigilance anwachsen. Folglich überlappen sich die Kategorien eines originalen FuzzyART stärker als die Kategorien eines modifizierten Systems mit  $\delta > 0$  und der gleichen Anzahl genutzter Neuronen. Zur Verdeutlichung stellt Abbildung 3 die durchschnittliche Anzahl  $\xi$  von Kategorien dar, in denen ein Input des verwendeten Trainingsdatensatzes bei einer bestimmten Anzahl  $N$  an  $F2$ -Neuronen enthalten ist.<sup>3</sup>




Abbildung 3. Durchschnittliche Anzahl  $\xi$  an Kategorien, in denen ein Input enthalten ist. Die Nutzung eines Parameters  $\delta \neq 0$  führt bei gleicher Neuronenzahl im Vergleich mit dem originalen FuzzyART ( $\delta = 0$ ) zu einer deutlichen Verringerung der Überlagerung von Kategorien.

Die Stabilität von FuzzyART bleibt bei dieser Modifikation erhalten; die Aktivierung eines Neurons

<sup>3</sup>Dabei wurden nur Inputs berücksichtigt, die sich in mindestens einer Kategorie befanden.

durch einen spezifischen Input kann sich aufgrund des Lernprozesses nicht verringern, da nur ein Anwachsen der Kategorien möglich ist. Aufgrund der deutlichen Beschränkung der Anzahl benötigter Neuronen in Kombination mit einer Reduzierung der Kategorieüberlagerungen stellt dieser Ansatz eine geeignete Ergänzung des originalen FuzzyART für die Lösung sensomotorischer Problemstellungen dar.

## 5 Ergebnisse

Die in den Abschnitten 3 und 4 vorgestellten Modifikationen von FuzzyART wurden am Beispiel einer Navigationsaufgabe für den Miniaturroboter KHEPERA eingesetzt [10]. Das Ziel des KHEPERA bestand dabei in der kollisionsfreien Bewegung in einem einfachen quadratischen Szenario, das außer seiner Begrenzung keine Hindernisse enthielt. Die Ermittlung der sensorischen Situationen erfolgte auf der Basis von Bildern der omnidirektionalen Farbbildkamera. Die Vigilance bzw. Basisvigilance wurde so gewählt, dass sowohl die Anzahl der genutzten  $F^2$ -Neuronen, als auch die Überlagerung der Kategorien möglichst gering waren [10]. Um die Anzahl an Neuronen zu begrenzen, kam für alle Systeme der in Abschnitt 4 beschriebene Ansatz mit einem Parameter  $\delta = 0.1$  zur Anwendung. Das so modifizierte FuzzyART benötigte nur 56 Neuronen. Im Vergleich zu einem originalen FuzzyART, das bei selber Vigilance 883 Neuronen nutzte, entspricht dies einer Reduzierung auf 6.34%. Der Einsatz des entsprechenden originalen FuzzyART-Systems war dabei aufgrund des erhöhten Rechenaufwandes in aufbauenden Verarbeitungsschritten, insbesondere der Handlungsgenerierung, praktisch nicht realisierbar.

Der Erwerb von Verhaltenswissen erfolgte auf der Basis von Reinforcement-Lernverfahren. Da die Aufgabe des KHEPERA in einer kollisionsfreien Bewegung bestand, erhielt der jeweilige Agent ein Reinforcementsignal von  $r(t) = 0$ , wenn seine Infrarotsensoren ein Hindernis erfassten und andernfalls ein Reinforcementsignal von  $r(t) = 1$ . Die Bedeutung der visuell erfassten sensorischen Situationen ergab sich also aus dem Reinforcementsignal, d.h.  $\Psi(\underline{x}(t)) = r(t)$ . Abbildung 4 zeigt, dass FuzzyART nur die Bedeutung der sensorischen Situationen korrekt repräsentiert, falls es entsprechend Abschnitt 3 bewertungsgesteuert wird.

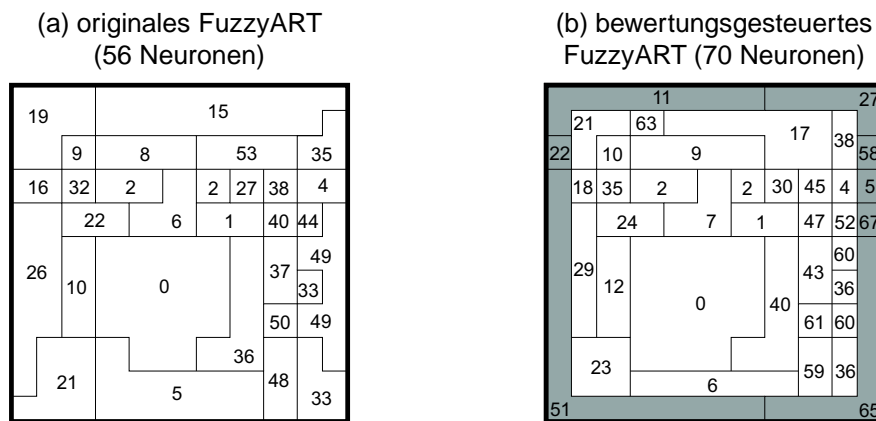


Abbildung 4. Repräsentation des Versuchsszenarios. An  $11 \times 11$  äquidistant im Szenario verteilten Messpunkten wurden die Best-Matching-Neuronen eines trainierten (a) originalen und (b) bewertungsgesteuerten FuzzyART-Systems ermittelt und an der entsprechenden Szenarioposition eingetragen. Im Gegensatz zum originalen FuzzyART repräsentiert das bewertungsgesteuerte FuzzyART Randsituationen mit  $\Psi(\underline{x}(t)) = 0$  (grau markiert) durch separate Neuronen.

Es konnte somit gezeigt werden, dass sowohl durch die Verringerung der Anzahl erforderlicher Neuronen nach Abschnitt 4, als auch die Integration der Bedeutung sensorischer Situationen in die Repräsentationsbildung nach Abschnitt 3 die Basis für die Handlungsgenerierung verbessert wird. Beide

Ansätze bilden damit geeignete Erweiterungen von FuzzyART für die Lösung sensomotorischer Problemstellungen.

## 6 Ausblick

Die in den Abschnitten 3 und 4 vorgestellten Ansätze sind nicht auf eine alleinige Anwendung mit FuzzyART beschränkt. Vielmehr können sie einfach auf alternative ART-Systeme übertragen werden, wodurch sich das Anwendungsgebiet deutlich vergrößert. Auch eine Beschränkung auf sensomotorische Aufgabenstellungen ist nicht vorhanden. Ein Beispiel für ein denkbare alternatives Aufgabengebiet der bewertungsgesteuerten Repräsentationsbildung (siehe Abschnitt 3) liegt in der inhaltsorientierten Clusterung von elektronischen Dokumenten im Internet. Die Bedeutung könnte sich hierbei beispielsweise aus der Größe der Dateien (Speicherplatz) ergeben. Infolgedessen würde ein Cluster nur inhaltlich verwandte Dokumente umfassen, die zusätzlich eine ähnliche Größe besitzen. Damit wäre es einem Nutzer dieses Systems möglich, Dokumente mit definiertem Inhalt zu suchen, wobei a priori Dokumente ausgeschlossen werden, die er aufgrund ihrer Größe mit seiner bestehenden Netzwerkverbindung nur schlecht herunterladen könnte. Somit wäre ein Nutzer schneller in der Lage, geeignete Dokumente zu erkennen. Auch die Reduzierung der benötigten Ressourcen (siehe Abschnitt 4) könnte in diesem Kontext hilfreich sein, z.B., wenn eine kontinuierliche Erweiterung der Dokumentenbasis gewünscht wird, aber nur eine eingeschränkte Rechenkapazität vorhanden ist.

## Literatur

- [1] G. A. Carpenter. Distributed learning, recognition, and prediction by ART and ARTMAP neural networks. *Neural Networks*, 10:1473–1494, 1997.
- [2] G. A. Carpenter, S. Grossberg, N. Markuzon, J. H. Reynolds, and D. B. Rosen. Fuzzy ARTMAP: A Neural Network Architecture for Incremental Supervised Learning of Analog Multidimensional Maps. In *IEEE Transactions on Neural Networks*, volume 3, pages 698–713, 1992.
- [3] G. A. Carpenter, S. Grossberg, and J. H. Reynolds. ARTMAP: Supervised real-time learning and classification of nonstationary data by a self-organizing neural network. *Neural Networks*, 4:543–564, 1991.
- [4] G. A. Carpenter, S. Grossberg, and D. B. Rosen. Fuzzy ART: Fast Stable Learning and Categorization of Analog Patterns by an Adaptive Resonance System. *Neural Networks*, 4:759–771, 1991.
- [5] B. Fritzke. A Growing Neural Gas Network Learns Topologies. *Advances in Neural Information Processing Systems*, 7:625–632, 1995.
- [6] S. Grossberg. Adaptive Pattern Classification and Universal Recoding, II: Feedback, Expectation, Olfaction, Illusion. *Biological Cybernetics*, 3:187–202, 1976.
- [7] K-Team. *Khepera User Manual*. K-Team, Ch. de Vuassett, CP 111, 1028 Préverenges, Switzerland, 1999. <http://www.k-team.com>.
- [8] T. Kohonen. Self-organized formation of topologically correct feature maps. *Biological Cybernetics*, 43:59–69, 1982.
- [9] T. Martinetz and K. J. Schulten. A “Neural-Gas” Network Learns Topologies. In T. Kohonen, K. Mäki-sara, O. Simula, and J. Kangas, editors, *Artificial Neural Networks*, pages 397–402, 1991.
- [10] A. Scheidig. *Sensomotorische Antizipation – ein neuer Zugang zur Verhaltensgenerierung*. PhD thesis, Technische Universität Ilmenau, Deutschland, 2003.
- [11] M. Tscherepanow und A. Heinze. *Bildung bewertungsgesteuerter sensorischer Repräsentationen*. Technical Report TR-NI-02-02, Technische Universität Ilmenau, Fachgebiet Neuroinformatik, 2002.
- [12] T. Villmann and M. Herrmann. Vector quantization by optimal neural gas. In W. Gerstner, A. Germond, M. Hasler, and J. D. Nicoud, editors, *Artificial Neural Networks—ICANN '97. 7th International Conference Proceedings*, pages 625–630. Springer-Verlag, Berlin, Germany, 1997.
- [13] J. R. Williamson. GaussianARTMAP: A Neural Network for Fast Incremental Learning of Noisy Multidimensional Maps. *Neural Networks*, 9:881–897, 1996.
- [14] A. Zell. *Simulation Neuronaler Netze*. Addison-Wesley, 1994.