Künstliches Lernen

Bernhard Schölkopf
Max–Planck–Institut für biologische Kybernetik, Tübingen

Der vorliegende Aufsatz bespricht zwei Formen des künstlichen Lernens, die auf unterschiedliche Lernbegriffe bauen. Beide ermöglichen die Konstruktion von Lernmaschinen, die durch Vergleich mit biologischen Systemen Rückschlüsse auf die Tragweite der zugrundeliegenden Lernbegriffe zulassen.

Die im Rahmen des ersten Ansatzes besprochene statistische Lerntheorie stellt für eine bestimmte Form des Lernens, das Lernen aus Beispielen, mathematische Ergebnisse bereit, welche die Bedingungen für erfolgreiches Lernen charakterisieren. Verschiedene Induktionsprinzipien werden vorgestellt und anhand von Lernmaschinen für das Problem der Mustererkennung illustriert. Der zweite Ansatz betont, daß Lernen der Organisation von Verhalten dient. Es wird ein Modell für räumliches Lernen bei Lebewesen besprochen, das durch ein künstliches neuronales Netzwerk auf einem mobilen Roboter implementiert wurde. Nach der Exploration eines Labyrinths können so Verhaltensleistungen hervorgebracht werden, die qualitativ denen von Tieren gleichen.

1. "Learning is the acquisition of knowledge about the world."[1]

2. "Learning is an adaptive change in behavior caused by experience."[2]

Beide Definitionen stammen von Neurobiologen. Die erste führt Lernen auf *Wissen* zurück — ein Begriff, der nicht weniger problematisch als der des Ler-

[1] I. Kupfermann (1985). Learning. In E. R. Kandel & J. H. Schwartz (Hrsg.), *Principles of Neural Science*, Elsevier, New York.

[2] G. M. Shepherd (1988). *Neurobiology*, Oxford University Press, New York.

nens erscheint. Bei wohlwollender Interpretation erlaubt sie es, auch Fälle von prozeduralem Lernen (z.B. ein Fahrrad zu fahren) einzuschließen. Die zweite Definition spricht stattdessen von *Verhalten*. Doch auch hier besteht Klärungsbedarf: ist das Hinken nach der Verletzung eines Beines oder das Gähnen nach einem langweiligen Vortrag eine durch Erfahrung bewirkte adaptive Verhaltensänderung, mithin eine Form des Lernens? Um dies auszuschließen, muß der Begriff der Adaptivität präzisiert werden. Auf der anderen Seite sollte der Begriff des Verhaltens weit genug gefaßt sein, um auch das Auswendiglernen eines Gedichtes einschließen zu können — ein Beispiel, mit dem die erste Definition keine Schwierigkeiten hätte.

In dem vorliegenden Aufsatz soll nicht versucht werden, eine dritte Definition zu formulieren. Stattdessen soll die Fruchtbarkeit eines synthetischen Zugangs zum Lernen exemplarisch vorgestellt werden: was können uns Lernmaschinen über das Lernen lehren? Unterschiedliche Typen von Lernmaschinen, aus der statistischen Lerntheorie und für das Lernen von kognitiven Karten, werden uns helfen, die Unterschiede und Gemeinsamkeiten der beiden obengenannten Definitionen zu illustrieren.

Statistische Lerntheorie

Lernen aus Beispielen

Lernen aus Beispielen wird in mehreren Disziplinen unter verschiedenen Namen studiert: während man in der statistischen Lerntheorie und im Bereich der Neuronalen Netze von *Lernen aus Beispielen* spricht, diskutiert die Mathematik *Funktionsapproximation*; die klassische Statistik wiederum befaßt sich mit der *Schätzung* von Funktionsparametern. Im folgenden soll die statistische Lerntheorie in der Formulierung Vapniks referiert werden.[3]

Das Problem des Lernens aus Beispielen wollen wir zunächst wie folgt formulieren: sei $y = f(\mathbf{x})$ ein unbekannter funktionaler Zusammenhang der Größen $\mathbf{x}$ und y. Ziel ist, aus einer begrenzten Anzahl von Beispielen (der *Trainingsmenge*) $(\mathbf{x}_1, y_1), \ldots, (\mathbf{x}_\ell, y_\ell)$ die Funktion f zu lernen.

Welche Aspekte gilt es hierbei zu berücksichtigen, um zu einer verläßlichen Schätzung f^* zu kommen? Zunächst einmal sollte die gelernte Funktion

[3]siehe V. Vapnik (1982). *Estimation of Dependences Based on Empirical Data*, Springer, New York; und V. Vapnik (1995). *The Nature of Statistical Learning Theory*, Springer, New York; dort finden sich auch Referenzen zu den Originalarbeiten.

die Beispiele *erklären*, d.h. $f^*(\mathbf{x}_1) = y_1, \ldots, f^*(\mathbf{x}_\ell) = y_\ell$, wenigstens näherungsweise. Abbildung 1 zeigt, daß dies noch nicht alles ist: die abgebildeten Beispiele werden durch die gestrichelte Funktion im Gegensatz zu der durchgezogenen Geraden vollständig erklärt; nichtsdestotrotz ist man geneigt, der Geraden mehr Vertrauen zu schenken. *Die Klasse der Funktionen, die man für die Lösung des Problems zuläßt, beeinflußt unser Vertrauen in die gefundene Lösung.* Die Formalisierung dieser Erkenntnis bildet den Kern der statistischen Lerntheorie.

ABBILDUNG 1

Der Einfachheit halber werden wir uns im folgenden auf *Mustererkennung* beschränken, d.h. auf Funktionen, die nur zwei verschiedene Werte annehmen können (*Entscheidungsfunktionen*). Obige Erkenntnis von der Wichtigkeit der zugelassenen Funktionen berücksichtigen wir, indem wir das Lernproblem wie folgt fassen:

Gegeben sei eine Menge von Entscheidungsfunktionen, und eine Menge von Trainingsbeispielen $(\mathbf{x}_1, y_1), \ldots, (\mathbf{x}_\ell, y_\ell)$*, zufällig erzeugt gemäß einer unbekannten Wahrscheinlichkeitsverteilung. Ziel ist es, eine Funktion auszuwählen, die den Zusammenhang zwischen* $\mathbf{x}$ *und* y *für Testbeispiele (gezogen aus derselben Wahrscheinlichkeitsverteilung) am besten wiedergibt.*[4]

Die *Muster* $\mathbf{x}$ könnten z.B. Repräsentationen von Krankheitssymptomen sein, aus denen auf das Vorhandensein y einer bestimmten Krankheit geschlossen werden soll. Der Zusammenhang zwischen $\mathbf{x}$ und y wird durch eine Wahrscheinlichkeitsverteilung $P(\mathbf{x}, y)$ modelliert. Diese enthält als Spezialfall die

[4] Mathematisch präziser ausgedrückt: Gegeben sei eine Menge von Funktionen

$$\{f_\alpha : \alpha \in \Lambda\},\ f_\alpha : \mathbf{R}^N \to \{\pm 1\},\ \mathbf{x} \mapsto y,$$

und eine Menge von Beispielen

$$(\mathbf{x}_1, y_1), \ldots, (\mathbf{x}_\ell, y_\ell), \quad \mathbf{x}_i \in \mathbf{R}^N, y_i \in \{\pm 1\},$$

erzeugt gemäß einer unbekannten Wahrscheinlichkeitsverteilung $P(\mathbf{x}, y)$. Ziel ist es, eine Funktion f_{α^*} zu finden, für die das *erwartete Risiko* (die Wahrscheinlichkeit für Klassifikationsfehler)

$$R(\alpha) = \int |f_\alpha(\mathbf{x}) - y| \; dP(\mathbf{x}, y)$$

minimal wird.
Die Indexmenge Λ, und damit die Menge von Funktionen f_α, darf im Gegensatz zur klassischen *parametrischen Statistik* beliebig groß sein.

Möglichkeit eines deterministischen Zusammenhanges $y = f(\mathbf{x})$. Da zu jedem Muster $\mathbf{x}_i$ der Zielwert y_i mitgeliefert wird, spricht man auch von *überwachtem Lernen.*

Die gesuchte Funktion soll den Zusammenhang zwischen $\mathbf{x}$ und y im Mittel am besten reproduzieren (die Wahrscheinlichkeit für Klassifikationsfehler bei Testbeispielen, das *(erwartete) Risiko*, soll minimal sein). Die Mittelung wird hierbei gemäß der Wahrscheinlichkeitsverteilung $P(\mathbf{x}, y)$ vollzogen. Da man diese nicht kennt, benötigt man ein *Induktionsprinzip*, um die Funktion (wenigstens näherungsweise) zu finden.

Eine *Lernmaschine* wird durch ein Menge von Funktionen (die die Maschine implementieren kann) und ein Induktionsprinzip zur Risikominimierung charakterisiert.

Induktionsprinzipien zur Risikominimierung

Eine naheliegende und vielfach verwendete Methode zur Risikominimierung minimiert das *empirische Risiko*, den Anteil der Fehlklassifikationen auf der Trainingsmenge.[5] Das Prinzip der empirischen Risikominimierung ist jedoch kein Garant für hohe *Generalisierungsfähigkeit*: ein nicht in der Trainingsmenge enthaltenes Beispiel, erzeugt gemäß derselben Wahrscheinlichkeitsverteilung, liegt nicht notwendig auf der gestrichelten Linie in Abbildung 1. In anderen Worten: von einem niedrigen empirischen Risiko alleine kann nicht auf ein niedriges erwartetes Risiko geschlossen werden. Hierzu muß gleichzeitig die *Vapnik–Chervonenkis–(VC–)Dimension* kontrolliert werden. Diese ist ein Maß für die Kapazität oder Komplexität einer Lernmaschine.[6]

Mithilfe der VC–Dimension ist es möglich, probabilistische obere Schranken für das erwartete Risiko anzugeben.[7] Diese setzen sich aus zwei Termen zusammen: aus dem empirischen Risiko und einem *Modellselektionsterm*, der

---

[5] $R_{emp}(\alpha) = \frac{1}{\ell}\sum_{i=1}^{\ell} |f_\alpha(\mathbf{x}_i) - y_i|$

[6] Die VC–Dimension einer Menge von Entscheidungsfunktionen ist die maximale Anzahl von Mustern, die durch Funktionen der Menge auf alle denkbaren Weisen in zwei Klassen eingeteilt werden können.

[7] Mit Wahrscheinlichkeit $\geq 1 - \eta$,

$$R(\alpha) \leq R_{emp}(\alpha) + \sqrt{\frac{\log(2\ell/h) + 1}{\ell/h} - \frac{\log(\eta/4)}{\ell}}$$

(h: VC–Dimension der Lernmaschine).

mit der VC–Dimension der Lernmaschine zunimmt. Anschaulich gesprochen: schafft man es, die Trainingsdaten mit einem *einfachen Modell* (d.h. einer Lernmaschine, deren VC–Dimension im Vergleich zur Anzahl der Trainingsbeispiele niedrig ist) zu *erklären* (d.h. das empirische Risiko gering zu halten), so besteht Grund zu der Annahme, daß der wirkliche funktionale Zusammenhang gefunden wurde. Kann man die Daten nur mit einer Maschine von vergleichsweise hoher VC–Dimension erklären, so ist dies nicht der Fall: die Maschine kann ihre Kapazität (VC–Dimension) dazu verwendet haben, die Beispiele einzeln zu memorisieren (*overfitting*), anstatt eine kompaktere zugrundeliegende Regularität zu lernen — demensprechend ist nicht zu erwarten, daß neue Beispiel zuverlässig klassifiziert werden können.[8] Das *Prinzip der strukturellen Risikominimierung* verwendet obengenannte Schranken, um das erwartete Risiko durch Kontrolle von empirischem Risiko und VC–Dimension zu minimieren, d.h. um eine Funktion innerhalb der Lernmaschine zu finden, die möglichst gut auf neue Beispiele generalisiert. Strukturelle Risikominimierung paßt also in diesem Sinne die Komplexität der Lernmaschine dem zu lösenden Problem an.

Streng genommen macht all dies noch keine Aussage darüber, ob es überhaupt Lernprobleme gibt, für die Generalisierung möglich ist. Wie schafft es der Konstrukteur einer Lernmaschine, diese mit einer Menge von Funktionen auszustatten, die trotz moderater VC–Dimension die Modellierung der zu lernenden Regularitäten gestattet? In der Tat lassen sich *no–free–lunch*–Theoreme beweisen, die besagen, daß es grob gesprochen zu jeder Regularität, die eine Lernmaschine lernen kann, eine andere gibt, für die die Maschine das Gegenteil tut, d.h. schlechter als ein zufälliger Klassifikator auf neue Beispiele generalisiert.[9] Tiefliegender als diese Erkenntnis ist jedoch die Frage, warum Lernmaschinen trotzdem funktionieren. Woran liegt es, daß die Funktionen, die wir in Lernmaschinen einbauen, sich überdurchschnittlich gut zur Modellierung von Regularitäten eignen, wie sie in unserer Umwelt vorkommen? Möglicherweise haben diese Regularitäten Gemeinsamkeiten, die wir im Lauf der Zeit extrahiert haben, oder die sie als "lernbar" identifizieren (und da-

[8] Ähnliche Ideen liegen dem *Prinzip der minimalen Beschreibungslänge* zugrunde: schafft man es, die Folge der $y_1, \ldots, y_\ell$ unter Verwendung der Kenntnis der $\mathbf{x}_1, \ldots, \mathbf{x}_\ell$ wesentlich zu komprimieren, so muß diese Kompression dem Datensatz intrinsische Regularitäten verwendet haben. Das erwartete Risiko wird in diesem Fall durch den Faktor der Kompression bestimmt.

[9] siehe z.B. D. H. Wolpert (1995). *Off-training set error and a priori distinctions between learning algorithms*, Working Paper 95-01-003, Santa Fe Institute, New Mexico, USA.

mit zu erkennbaren Regularitäten machen?); möglicherweise teilt auch unser Erkenntnisapparat (der Hypothesen für Funktionen aufstellt) diese Gemeinsamkeiten und muß sie daher nicht erst extrahieren. Im letzteren Fall könnte ein gemeinsames Prinzip verantwortlich zeichnen — Regularitäten und Funktionshypothesen könnten beispielsweise beide von begrenzter *algorithmischer Komplexität* sein. Diese von Kolmogorov zur Definition von Zufälligkeit erdachte Größe (*zufällig* bedeutet von hoher algorithmischer Komplexität) ist die Länge des kürzesten binären Computerprogramms, welches ein gegebenes Objekt charakterisiert.[10]

Abschließend soll noch auf eine bemerkenswerte Parallele zur Wissenschaftstheorie hingewiesen werden — letztere beschäftigt sich ja unter anderem auch mit dem Problem der Induktion. Eine Lernmaschine heißt *nicht falsifizierbar* (für eine gegebene Wahrscheinlichkeitsverteilung), wenn sie für beliebige Mengen von gemäß der Wahrscheinlichkeitsverteilung erzeugten Beispielen alle denkbaren Kombinationen von Klassenzugehörigkeiten erklären kann.

Es kann bewiesen werden, daß für Lernmaschinen, die überall im Musterraum falsifizierbar sind, das Prinzip der empirischen Risikominimierung *konsistent* ist, d.h. bei hinreichend vielen Beispielen eine Funktion wählt, deren erwartetes Risiko beliebig dicht am minimal möglichen Wert liegt.[11] Konsistenz für alle möglichen Wahrscheinlichkeitsverteilungen ist äquivalent zur Endlichkeit der VC–Dimension.

Lernmaschinen für überwachtes Lernen

Mehrschichtige Perzeptrons sind einfache Neuronale Netzwerke ohne rückgekoppelte Verbindungen, die sich in Schichten anordnen lassen (Abbildung 2). Typischerweise legt man zunächst eine Netzwerkarchitektur fest und fixiert so die Menge von Funktionen, die das Perzeptron implementieren kann. Dadurch wird auch die VC–Dimension der Lernmaschine festgelegt, und die Minimierung des erwarteten Risikos wird anschließend durch empirische Risikominimierung angestrebt. Zu diesem Zweck betrachtet man den Fehler bei der Klassifikation der Beispiele als eine Funktion der Netzwerkparameter, und versucht

[10] A. N. Kolmogorov (1965). Three approaches to the quantitative definition of information. *Problems of Information Transmission*, 1:1 – 7.

[11] V. Vapnik & A. Ya. Chervonenkis (1991). The necessary and sufficient conditions for consistency in the empirical risk minimization method. *Pattern Recognition and Image Analysis*, 1(3):283 – 305; vgl. K. Popper (1935). *Logik der Forschung*, Julius Springer Verlag, Wien.

diese Funktion schrittweise durch Änderung der Parameter zu minimieren. In der Regel verwendet man hierzu den *Backpropagation*–Algorithmus.[12]

ABBILDUNG 2

Da man so die VC–Dimension des Netzwerkes nicht explizit beeinflussen kann, wird das Netzwerk nur dann neue Beispiele korrekt klassifizieren, wenn die ursprüngliche Wahl der Netzwerkarchitektur dem Problem angemessen war. Um diesem Umstand abzuhelfen, ist eine Reihe von Heuristiken zur Komplexitätskontrolle vorgeschlagen worden; so können beispielsweise entbehrliche Gewichte entfernt werden (*Optimal Brain Damage*), alternativ kann die Anzahl der freien Gewichtsparameter reduziert werden, indem man Teilmengen von Gewichten in ihren Werten aneinander koppelt.[13]

Um das erwartete Risiko zu minimieren, müssen sowohl die VC–Dimension als auch das empirische Risiko kontrolliert werden (strukturelle Risikominimierung). *Support–Vektor–Maschinen*[14] tun dies, indem sie die Muster effektiv in einen hochdimensionalen Raum abbilden und dort eine Hyperebene zur Separation der beiden Klassen konstruieren. Für diese einfache Klasse von Entscheidungsfunktionen läßt sich die VC–Dimension angeben und algorithmisch kontrollieren. Durch Lösung eines quadratischen Optimierungsproblems findet man die Funktion, die die beste Generalisierungsleistung verspricht. Es stellt sich heraus, daß diese Funktion nur von wenigen Trainingsbeispielen, den *Support–Vektoren*, abhängt. Klassifikation eines neuen Musters geschieht durch gewichteten Vergleich mit den Support–Vektoren. Unterschiedliche Typen von Support–Vektor–Maschinen, die sich durch die Wahl einer Vergleichsfunktion K (siehe Abbildungen 3 und 4) implementieren lassen, extrahieren fast identische Mengen von Support–Vektoren; und eine Maschine, die nur auf den Support–Vektoren trainiert wird, generalisiert genausogut wie nach dem Training auf der gesamten Trainingsmenge (und besser als herkömmliche Neuronale Netze). In diesem Sinne sind die Support–Vektoren charakteristisch für das zu lösende Mustererkennungsproblem.[15]

---

[12] Eine gute Einführung in die Thematik der Neuronalen Netze ist J. Hertz, A. Krogh & R. G. Palmer (1991). *Introduction to the Theory of Neural Computation.* Addison–Wesley, Redwood City, CA, USA.

[13] siehe Y. Le Cun, J. S. Denker & S. A. Solla (1990). Optimal Brain Damage. In D. S. Touretzky (Hrsg.), *Advances in Neural Information Processing Systems 2*, Morgan Kaufmann, San Mateo, CA, USA, und dort aufgeführte Referenzen.

[14] V. Vapnik (1995), a.a.O.

[15] B. Schölkopf, C. Burges & V. Vapnik (1995). Extracting support data for a given task.

ABBILDUNG 3

Generalisierung wird hier also durch die Memorisierung ausgewählter Beispiele erreicht. Ein attraktiver Aspekt einer solchen beispiel–basierten Form von Mustererkennung ist die biologische Möglichkeit ihrer Entwicklung aus einfachen assoziativen Reflexen.[16]

ABBILDUNG 4

Das Erlernen kognitiver Karten

Die im ersten Teil des Kapitels besprochene Einschränkung des Lernbegriffs auf das Lernen eines funktionalen Zusammenhangs aus Beispielen hat den Vorteil, eine tiefgehende statistische Analyse zu ermöglichen. Einfache Modelle von Neuronalen Netzen, wie zum Beispiel Perzeptrons, wurden zwar durchaus zur Modellierung von bestimmten Aspekten des Lernens eingesetzt; indes lassen sich viele aus der Biologie bekannte Formen des Lernens nicht auf dieses vereinfachte Schema reduzieren. Zum einen geschieht Lernen bei Tieren oft ohne oder mit nur geringer Überwachung — diesem wurde durch die Entwicklung von Regeln für *unüberwachtes Lernen (Selbstorganisation)* und *Verstärkungslernen (reinforcement learning)* Rechnung getragen. Zum anderen wurde argumentiert, daß Lernprozesse in der Modellierung durch Neuronale Netze wesentliche Aspekte der Wechselwirkung mit der Umwelt (*embodiment*) vernachlässigen — dies führte beispielsweise zur Diskussion von *perception for action* und zur Entwicklung von als Robotern implementierten *animats* (eine Neubildung: belebte Automaten; auch unter dem Begriff *artificial life* firmierend).[17]

In U. M. Fayyad & R. Uthurusamy (Hrsg.), *Proceedings, First International Conference on Knowledge Discovery & Data Mining.* AAAI Press, Menlo Park, CA, USA. Eine weitere interessante Eigenschaft von Support–Vektoren ist, daß man durch Erzeugung transformierter Bilder der Support–Vektoren Wissen um Transformationsinvarianzen des Klassifikationsproblems in die Entscheidungsfunktion einbauen kann.

[16]T. Poggio (1990). A theory of how the brain might work. *AI Memo No. 1253*, Artificial Intelligence Laboratory, Massachusetts Institute of Technology, USA.

[17]Siehe z.B. V. Braitenberg (1984). *Vehicles. Experiments in Synthetic Psychology.* MIT Press, Cambridge, MA, USA; D. Cliff, P. Husbands, J.–A. Meyer & S. W. Wilson (Hrsg.) (1994). *From Animals to Animats 3: Proceedings of the Third International Conference on Simulation of Adaptive Behavior.* MIT Press, Cambridge, MA, USA; D. H. Ballard (1991). Animate vision. *Artificial Intelligence*, 48:57 – 86.

Räumliches Verhalten

Mit der Fähigkeit zur Bewegung innerhalb der Umgebung hat sich im Tierreich *räumliches Verhalten* entwickelt.[18] In diesem Verhalten spiegeln sich sowohl die natürliche Umgebung eines Lebewesens — das Wasser gestattet den Fischen, sich in allen drei Raumdimensionen zu bewegen — als auch die Wahrnehmungsinstrumente (*Sensoren* — hierunter sollen im folgenden sowohl *Exterozeptoren* als auch *Propriozeptoren* verstanden werden, d.h. auf externe bzw. interne Stimuli reagierende Sensoren). Sensoren bestimmen, wie sich die Umwelt für ein Lebewesen präsentiert — so erlauben uns visuelle und taktile Sensoren beispielsweise die Ausführung von Greifvorgängen, was unsere Möglichkeiten der Umwelterfahrung und damit unser Umweltbild wesentlich erweitert.

Mit nur einem Sensor betrachtet, sieht die räumliche Umgebung völlig anders aus,[19] und doch kann dieser Sensor schon die Hervorbringung räumlichen Verhaltens ermöglichen: bewegt sich ein so ausgestattetes Lebewesen in einem günstigen Milieu grundsätzlich langsamer, oder dreht es sich häufiger, so wird es sich effektiv länger dort aufhalten (*Kinesis*). Eine weitere Form von räumlichem Verhalten, die *phobische Reaktion*, besteht in der Auslösung einer festgelegten Fluchtreaktion durch das Vorhandensein eines Umweltreizes. Bei den *Kühnschen Taxien* hängt die Reaktion auch von der Größe des Reizes ab. So verwendet beispielsweise die *Tropo–Taxis* zwei symmetrisch angebrachte Sensoren, um eine räumliche Orientierung auf eine Reizquelle hin zu erreichen.

Höherstehendes räumliches Verhalten erfordert die Verarbeitung von umfangreicherer Information. Die Wüstenameise *Cataglyphis* mißt Drehwinkel und zurückgelegte Wegstrecken, um nach ausgedehnter Futtersuche geradlinig zu ihrem Nest zurückzukehren (*Pfadintegration*).

Von *kognitiven Karten* spricht man in der Regel erst bei Wirbeltieren. Es handelt sich hierbei um neuronale Mechanismen, die wie Landkarten höhere Navigations– und Orientierungsleistungen ermöglichen. So können zum Beispiel Ratten über ihre Umgebung Gelerntes auf neue Weise zusammensetzen, um Umwege zu finden, wenn sie durch plötzlich vorhandene Hindernisse in Labyrinthen dazu gezwungen werden. Ein mögliches Substrat für derartiges Verhalten wurde in neurophysiologischen Untersuchungen gefunden: im Gehirn von Ratten befinden sich Nervenzellen, deren Aktivität auffallend stark

---

[18] K. Lorenz (1973). *Die Rückseite des Spiegels.* R. Piper & Co. Verlag.; H. Schöne (1980). *Orientierung im Raum.* Wissenschaftliche Verlagsgesellschaft mbH, Stuttgart, 1980.

[19] die unangebrachte Verwendung des sinnlichen Verbs *sehen* illustriert hier die Unfähigkeit, sich diese Umgebung vorzustellen

mit dem räumlichen Aufenthaltsort der Tiere korreliert ist (*Platzzellen*).[20] Diese Aktivität wird von sensorischen Wahrnehmungen beeinflußt, sie scheint jedoch auch von dem Wissen einer Ratte um ihren räumlichen Aufenthaltsort abzuhängen: wird während eines Experiments das Licht ausgeschaltet, so mißt man im folgenden nur wenig veränderte Erregungsmuster in den Platzzellen; schaltet man das Licht hingegen *vor* dem Experiment aus — und nimmt der Ratte dadurch die Möglichkeit, visuelle Information zur Ausbildung einer Vorstellung von ihrem räumlichen Aufenthaltsort zu verwenden — so fehlen die charakteristischen Erregungsmuster, ungeachtet der Tatsache, daß die Ratte die Umgebung aus vorangegangenen Experimenten noch kennt.

Platzzellen finden sich zuhauf im *Hippocampus* von Ratten. Dieser Gehirnteil, der aus einer Vielzahl von Gehirnarealen gespeist wird, scheint jedoch nicht nur bei der Verarbeitung räumlicher Information eine wichtige Rolle zu spielen. Studien zur *retrograden Amnesie* legen die Vermutung nahe, daß er für die Aufnahme und Weiterverarbeitung deklarativen Wissens wesentlich ist: Patienten mit hippocampalen Verletzungen erleiden Lernstörungen, gekoppelt mit Amnesien, die eine gewisse Zeit in die Vergangenheit zurückreichen. Erinnerungen, die sich zur Zeit der Verletzung bereits im Langzeitgedächtnis befanden, sowie die Verarbeitung nicht–deklarativen Wissens, zum Beispiel der Erwerb von motorischen Fertigkeiten, bleiben intakt.[21]

Wenn nun die Nervenzellen des Hippocampus wesentlich für bestimmte Lernvorgänge sind, gleichzeitig aber ein großer Prozentsatz von ihnen räumliche Information verarbeitet, so liegt es nahe, räumliches Lernen als paradigmatisch für diese Lernvorgänge zu betrachten. Im folgenden soll ein Modell zur räumlichen Orientierung und Pfadplanung vorgestellt werden, das als elementaren Baustein den Zusammenhang zwischen einer Kombination aus Position und Bewegungsentscheidung und dem so erreichbaren benachbarten Ort verwendet. Eine Vielzahl von nicht räumlichen Planungsaufgaben läßt sich in dasselbe Schema fügen: ein Zustand und eine Aktion führen zu einem neuen Zustand. Noch allgemeiner sieht Konrad Lorenz Denken "als ein solches probeweises und nur im Gehirn sich abspielendes Handeln im vorgestellten

[20]siehe z.B. B. L. McNaughton und L. Nadel (1990). Hebb–Marr networks and the neurobiological representation of action in space. In M. A. Gluck & D. E. Rumelhart (Hrsg.), *Neuroscience and Connectionist Theory*, S. 1 – 63. Lawrence Erlbaum Associates, Hillsdale, NJ, USA.

[21]Eine Übersicht der verschiedenen Gedächtnissysteme findet sich bei E. Tulving (1995). Organization of memory: quo vadis?, in M. S. Gazzaniga (Hrsg.), *The Cognitive Neurosciences*, MIT Press, Cambridge, USA.

Raum."[22]

Ein Modell zur räumlichen Orientierung in Labyrinthen

Im folgenden soll das *Ansichtsgraph–Modell* von Schölkopf & Mallot referiert werden.[23]

Repräsentation des Raumes

Die Wahl einer geeigneten Repräsentation von räumlicher Information hängt wesentlich von drei Faktoren ab: sie baut auf die Art der zugänglichen Information auf — diese wird von der *Umgebung* und den vorhandenen *Sensoren* bestimmt — und sie soll ein Repertoire von erwünschten *Verhaltensweisen* ermöglichen.[24]

Das vorliegende Modell operiert in einer diskretisierten Umwelt, bestehend aus Korridoren und Knoten — einem Labyrinth (Abbildung 5) —, es verwendet idealisierte visuelle Sensoren und einen Sensor, der die getroffene Bewegungsentscheidung in den Labyrinthknoten anzeigt. Nach einer Exploration des Labyrinthes soll das Modell dazu in der Lage sein, Wege zwischen beliebigen Punkten zu planen.

Da die Labyrinthknoten durchaus unterschiedlich aussehen können, wenn man sich Ihnen aus verschiedenen Richtungen nähert, wollen wir des weiteren annehmen, daß nicht die *Knoten*, sondern die gerichteten *Korridore* zwischen den Knoten durch eindeutige visuelle Informationen charakterisiert sind. Eine Exploration des Labyrinths führt dann zu einer Sequenz von für die Korridore

[22] a.a.O. (1973)

[23] B. Schölkopf und H. A. Mallot (1995). View–based cognitive mapping and path planning. *Adaptive Behavior*, 3:311 – 348. Für Zitate anderer Originalarbeiten wird auf diese Veröffentlichung verwiesen, aus der auch die nachfolgenden Abbildungen in abgewandelter Form übernommen wurden.

[24] In diesem Zusammenhang spricht man auch von *internen Weltmodellen*. Zweck solcher Modelle ist nicht, ein umfassendes und getreues Bild der Welt zu liefern: "In that Empire, the craft of Cartography attained such Perfection that the Map of a Single province covered the space of an entire City, and the Map of the Empire itself an entire Province. In the course of Time, these Extensive maps were found somehow wanting, and so the College of Cartographers evolved a Map of the Empire that was of the same Scale as the Empire and that coincided with it point for point. Less attentive to the Study of Cartography, succeeding Generations came to judge a map of such Magnitude cumbersome, and, not without Irreverence, they abandoned it to the Rigours of sun and Rain." (J. L. Borges (1975). Of Exactitude in Science. *A Universal History of Infamy*, Penguin Books, London)

charakteristischen *Ansichten* und *Bewegungsentscheidungen*. Räumliche Nachbarschaft im Labyrinth wird hierbei in zeitliche Nachbarschaft in der Sequenz verwandelt.

ABBILDUNG 5

Um später Pfadplanung ausführen zu können, müssen sowohl die Ansichten als auch die räumlichen Nachbarschaftsverhältnisse (die *Topologie*) und die zwischen benachbarten Orten vermittelnden Bewegungen gelernt werden. Ziel der Exploration ist es also, aus der Explorationssequenz den *Ansichtsgraphen* zu konstruieren, welcher die möglichen Folgen von Ansichten zusammen mit den vermittelnden Bewegungsentscheidungen beinhaltet (Abbildung 6).

ABBILDUNG 6

Es läßt sich mathematisch zeigen, daß dieser Graph hinreichende Information zur Rekonstruktion des Labyrinthgraphen (Abbildung 5) beinhaltet; der Beweis verwendet die Tatsache, daß zwei Ansichten (gerichtete Korridore) genau dann zum selben Platz führen, wenn sie dieselben möglichen Nachfolgeansichten haben. Für die Erzeugung von Pfadplanungsverhalten muß diese Rekonstruktion jedoch nicht ausgeführt werden. Im nächsten Abschnitt wird ein Verfahren vorgestellt, mit dem optimale Pfade direkt aus dem Ansichtsgraphen berechnet werden können. Für die Erzeugung der angestrebten Verhaltensweisen ist es also nicht notwendig, eine Karte aufzubauen, die der Struktur der Umwelt direkt entspricht.

Ein Neuronales Netz

Die Konstruktion des Ansichtsgraphen aus einer zufälligen Exploration eines Labyrinths verlangt die Lösung von drei Teilproblemen, denen unterschiedliche Aspekte des Netzwerkmodells gewidmet sind:

Erkennen von Ansichten. Während der Exploration werden für unterschiedliche Ansichten stehende Aktivitätsmuster auf die Eingabeschicht gelegt und über einen Satz von unterschiedlich gewichteten Eingangsverbindungen an die Kartenschicht weitergeleitet. Durch eine geeignete Lernregel zur adaptiven Veränderung der Gewichte wird erreicht, daß sich verschiedene Zellen auf die unterschiedlichen Ansichten des Labyrinthes spezialisieren (*Ansichtszellen*[25]). Erfolgreich gelernte Ansichten werden *erkannt*, indem spezifische Zellen *(Gewinner)* maximal erregt sind.

Erlernen der Labyrinth–Topologie. Eine kompetitive Lernregel sorgt dafür, daß die Gewinner–Zellen von aufeinanderfolgenden Zeitschritten, d.h. Zellen, die auf benachbarte Ansichten spezialisiert sind, über ein laterales Gewicht in der Kartenschicht verbunden werden. Demzufolge wird nach erfolgtem Lernen das Verbindungsmuster innerhalb der Kartenschicht dem Ansichtsgraphen gleichen. Die lateralen Gewichte bewirken, daß die Ansichtszellen nicht nur von visuellen Reizen angetrieben werden, sondern auch Wissen um die Labyrinth–Topologie mit einbeziehen.

Erlernen der Bewegungsentscheidungen. Zu jeder der Verbindungen in der Kartenschicht (bzw. im Ansichtsgraphen) gehört eine eindeutige Bewegungsentscheidung. Diese wird durch eine von drei Bewegungszellen ausgehende Verbindung codiert. Aktivität in den Bewegungszellen gewinnt einen modulatorischen Einfluß auf die Verbreitung von Aktivitätsmustern innerhalb der Kartenschicht, indem über diese Verbindungen die lateralen Gewichte in der Kartenschicht verändert werden.

ABBILDUNG 7

Für die Pfadplanung werden die möglichen Bewegungsentscheidungen von dem gegebenen Startpunkt aus nach folgender Prozedur verglichen: zunächst wird jeweils die entsprechende Bewegungszelle aktiviert und nach einem Zeittakt die neue Gewinnerzelle ermittelt. Da sich die Aktivität von der die Startansicht codierenden Zelle gemäß dem Verbindungsmuster der Kartenschicht verbreitet, sollte dies die Zelle sein, die die durch die gewählte Bewegungsentscheidung erreichbare Ansicht codiert. Sodann wird die Zeit gestoppt, die ein Aktivitätspuls von jener Zelle zu der die Zielansicht codierenden Zelle benötigt. Diese Zeit ist ein Maß für die Distanz zum Ziel, und so kann der erste Bewegungsschritt so gewählt werden, daß er zu der Ansicht führt, die von allen Nachbaransichten der Karte nach am nächsten zum Ziel ist. Die folgenden Schritte des zu planenden Pfades werden entsprechend ermittelt, mit dem Unterschied, daß zu Beginn nicht die ursprüngliche Startzelle aktiviert ist, sondern

[25]Der Name wurde in Anlehnung an obengenannte Platzzellen gewählt. Tatsächlich ist auch die Aktivität von Platzzellen meist richtungsabhängig.

die durch die vorangegangenen Schritte erreichte Zelle. Sobald die Zielansicht erreicht ist, wird der Prozeß abgebrochen. Zusammenfassend wird also eine Sequenz von Bewegungsentscheidungen gleichsam durch Simulation von Bewegungen auf der Karte ermittelt — ein Vorgang, der durchaus der Methode ähnelt, mit der man Landkarten liest. In der Tierpsychologie spricht man seit Tolman von *stellvertretendem Versuch–Irrtum–Verhalten.*[26]

Erzeugtes Verhalten

In Experimenten wurden Labyrinthe mit 12 bis 24 Ansichten und Neuronale Netze mit rund 200 Zellen verwendet. Die Labyrinthansichten wurden als zufällig erzeugte 20–dimensionale Vektoren modelliert, die entsprechend der Zufallsexploration des Labyrinths sequentiell auf die Eingabeschicht des Netzes gegeben werden. Je nach Labyrinthgröße braucht man 100 bis 300 Explorationsschritte, um den Ansichtsgraphen vollständig zu lernen. Verwendet man die Information, daß dem Ansichtsgraphen ein Labyrinthgraph zugrunde liegt, so kann diese Lernzeit auf weniger als die Hälfte verkürzt werden.[27] Die im folgenden referierten Ergebnisse wurden in Simulationen und in Experimenten mit einem mobilen Roboter gewonnen.[28] Im letzteren Fall werden die Ansichten aus der raum–zeitlichen Information gewonnen, die von zwei Infrarotsensoren entlang der Korridore aufgenommen wird.

Pfadplanung. Das Neuronale Netz ist in der Lage, Verbindungen zwischen beliebigen Orten (Ansichten) des Labyrinths zu finden. Hierbei muß während des Lernens noch nicht bekannt sein, welche Pfade nach vollendeter Exploration zu planen sein werden. Diese Form von *latentem Lernen* ist beispielweise aus Verhaltensexperimenten mit Ratten bekannt. Darüberhinaus kann das

[26]E. C. Tolman (1932). *Purposive Behavior of Animals and Men.* Irvington, New York, USA.

[27]Im Kontext von Neuronalen Netzen spricht man hierbei von der Einbeziehung von *a–priori*–Wissen, oder — wenn man die unorthodoxe Verwendung von *a priori* vermeiden will — von *Bereichswissen (domain knowledge).* Interessierte Leser mögen sich klarmachen, daß dieses Wissen für das abgebildete Labyrinth zu einer minimalen Explorationsdauer von 17 Schritten führt. Des weiteren könnte man das Wissen verwenden, daß der Labyrinthgraph planar ist und alle Korridore bidirektional sind.

[28]B. Schölkopf & H. A. Mallot (1995), a.a.O.; H. Mallot, H. Bülthoff, P. Georg, B. Schölkopf, und K. Yasuhara (1995). View–based cognitive map learning by an autonomous robot. In F. Fogelman-Soulie und P. Gallinari (Hrsg.), *Proceedings ICANN'95 — International Conference on Artificial Neural Networks.* EC2 & Cie, Paris.

Netz Pfade planen, die es so während der Exploration nie gesehen hat. Dies geschieht, indem Teile von bekannten Pfaden neu zusammengesetzt werden.

Erwartungen/Kontext. Da die Information über die Ansichten, enthalten in den Eingangsgewichten des Netzes, zusammen mit der Information über Nachbarschaftsverhältnisse (laterale Gewichte in der Kartenschicht) und Bewegungsentscheidungen (modulatorische Verbindungen von den Bewegungszellen zur Kartenschicht) codiert ist, kann das Netz sein Wissen um die Struktur des Labyrinths verwenden, um die Erkennung von Ansichten robuster zu machen. Wird eine bestimmte Bewegung ausgeführt, so verbreitet sich währenddessen die Aktivität in der Kartenschicht von der die letzte Ansicht codierenden Zelle zu den damit vernetzten Zellen — also gerade zu denen, von den bekannt ist, daß sie benachbart sind —, moduliert durch die Aktivität der Bewegungszelle. Dadurch erhält die Zelle der Ansicht, die das Netz als benachbart *erwartet*, einen lateralen Input, der sie zusammen mit dem Input aus der Eingabeschicht (von der neuen Ansicht herrührend) mit hoher Wahrscheinlichkeit zur Gewinnerzelle macht. Mit diesem Mechanismus sind auch die zuvor besprochenen Experimente, bei denen das Licht abgeschaltet wird und das Feuern der Platzzellen weitergeht, qualitativ reproduzierbar.

Diskussion

Repräsentation. Die im vorgestellten Modell verwendete Repräsentation des Raumes wird aus Stimuli konstruiert, die zum Teil intern auftreten und zum Teil zwar von außen stammen, aber nur über einen vorgegebenen Kanal in eine dem Neuronalen Netz verständliche Sprache übersetzt werden. Man möge sich dies am Beispiel des Roboters klarmachen: die einzige aus der physikalischen Umwelt aufgenommene Information ist ein Strom von Meßwerten weniger Infrarotsensoren. Dementsprechend ist die gelernte kognitive Karte kein einfaches *Abbild* der Umgebung, sondern ein für die Hervorbringung bestimmter Verhaltensweisen entwickeltes *Werkzeug.*[29] Abbildung 8 zeigt, wie anhand

[29] In einem ähnlichen Spannungsfeld bewegt sich die Diskussion der Repräsentation von Objekten zum Zweck ihrer Erkennung: speichern wir die volle dreidimensionale Struktur von Objekten, um sie mittels mentaler Rotation und Projektion mit wahrgenommenen (zweidimensionalen) Bildern in Übereinstimmung zu bringen, oder sollten nicht weniger aufwendige pragmatische Modelle dieselben Verhaltensleistungen ermöglichen? Vgl. H. H. Bülthoff & S. Edelman (1993). Evaluating object recognition theories by computer graphics psychophysics. In T. A. Poggio und D. A. Glaser (Hrsg.), *Exploring Brain Functions: Models in*

des Ansichtsgraphen navigiert wird. Die Rekonstruktion der Labyrinthstruktur ist zwar möglich, aber nicht notwendig. Aufgabe des Neuronalen Netzes ist nur, adäquates Verhalten zu erzeugen. Dies geschieht in einem Zyklus aus Wahrnehmung und Handlung.

ABBILDUNG 8

Unüberwachtes Lernen. Im Gegensatz zu dem zu Beginn des Kapitels besprochenen Paradigma des überwachten Lernens entsteht die kognitive Karte durch Selbstorganisation. Wollte man die Karte überwacht lernen, so müßten die Beispiele folgende Form haben: eine Ansicht und eine Bewegungsentscheidung führen zu einer neuen Ansicht. Das vorliegende System lernt die Karte während einer Labyrinthexploration; hierbei werden die Beispiele nicht zufällig gemäß einer bestimmten Wahrscheinlichkeitsverteilung erzeugt, sondern aktiv gewählt. Durch die besondere Form der Kopplung des Explorationssystems mit dem Labyrinth, die räumliche in zeitliche Nachbarschaft verwandelt, erzeugt sich das System diese Beispiele implizit selbst.

Eine natürliche Erweiterung des Modells ist die Einführung eines Ensemble–Codes für die Ansichten. In diesem Fall würde die Wahrnehmung einer Ansicht durch das gesamte Aktivitätsmuster auf der Kartenschicht codiert werden, nicht nur durch sein Maximum. Mit entsprechend modifizierten Lernregeln für die Gewichte erhielte man so einen *Assoziativspeicher*, der Muster verbindet, mit der zusätzlichen Eigenschaft, daß bestimmte Musterabfolgen durch die Aktivierung spezifischer Bedingungen (hier: Bewegungszellen) erzeugt werden können. Ein Vorteil einer Ensemble–Codierung ist, daß der Ausfall einiger Zellen oder Gewichte nur zu einer graduellen Beeinträchtigung der Funktionalität führt. In dem vorgestellten Netzmodell trifft dies auf die Eingangsgewichte zu, jedoch nicht auf die Ansichtszellen.

Schluß

Zwei verschiedene Formen des Lernens wurden besprochen. Die erste, theoretisch gut untersuchte Form beschäftigt sich mit der Extraktion von in der Wirklichkeit vermuteten Regularitäten aus einem Datensatz — man könnte von der Aneignung von Wissen über die Welt im Sinne der ersten der eingangs

Neuroscience, 139 – 164. John Wiley & Sons Ltd., New York.

aufgeführten Definitionen des Lernbegriffs sprechen. Die zweite, hier anhand eines Beispiels aus der Navigation besprochene Form beschränkt sich auf das Hervorbringen von Verhalten, in Übereinstimmung mit der zweiten Definition. Beiden Formen gemeinsam ist, daß sie zwar des der Umwelt entstammenden empirischen Materials bedürfen, erfolgreiches Lernen jedoch nur dann möglich ist, wenn interne Eigenschaften der Lernmaschine (angepaßte Architektur und VC–Dimension) dies unterstützen. In diesem Sinne ist Lernen ein Prozeß, der externe Stimuli nicht anhäuft, sondern vielmehr in ein vorgefaßtes Schema fügt.

Selbstverständlich könnte ein Erkennungsystem, wie im ersten Teil des vorliegenden Textes besprochen, sehr wohl Teil eines größeren Systems sein, welches Verhalten hervorbringt; so zum Beispiel in einem Zebrafinken, der durch Prägung lernt, seine späteren Sexualpartner zu erkennen, was zur Auslösung von Paarungsverhalten notwendig ist. Ist die Hervorbringung von Verhalten das einzige Ziel, so muß jedoch immer die Frage erlaubt sein, ob es sich nicht mit einfacheren Mitteln hätte erreichen lassen — die Evolution bevorzugt direkte Lösungen. Auch in der Statistik setzt sich dieses Prinzip zunehmend durch. In der ersten Hälfte dieses Jahrhunderts wurden Mustererkennungsprobleme noch gelöst, indem zunächst für die zu separierenden Klassen Wahrscheinlichkeitsdichten geschätzt wurden, um danach daraus die Klassifikationsfunktion abzuleiten. Viel sinnvoller ist es, wie in diesem Beitrag besprochen, die Klassifikationsfunktion ohne Umwege zu ermitteln. Aber auch das kann noch zu viel sein: unter Umständen interessiert man sich nur für den Wert dieser Funktion an einem bestimmten Punkt, und kann dementsprechend letzteren direkt schätzen. In manchen Fällen will man die Entscheidungsfunktion gar überhaupt nicht auswerten, sondern nur aus einer gegebenen Menge von Mustern dasjenige bestimmen, daß mit der höchsten Wahrscheinlichkeit zu einer bestimmten Klasse gehört. So könnte ein Tier zum Beispiel daran interessiert sein, aus einer Menge von Objekten dasjenige zu wählen, das am ehesten eßbar ist, anstatt für jedes einzelne die Frage der Eßbarkeit entscheiden zu müssen. Direkte Inferenzen dieses Typs werden von Vapnik *transduktiv* genannt.

Die statistische Lerntheorie beschäftigt sich mit allgemeinen Gesetzen, die für lernende Systeme gültig sind. Diese Gesetze erlauben die Synthese von Lernmaschinen, die aus begrenzten Beobachtungen und Erfahrungen effizient lernen. Die konkrete Implementierung von Lernmaschinen muß Antworten auf Fragen wie Speicher– und Rechenaufwand, sowie Universalität einer zu wählenden Repräsentation finden; sie könnte Aufschluß darüber geben, in welchem Umfang induktive bzw. transduktive Inferenz der Hervorbringung von Verhalten in Lebewesen zugrundeliegen kann.

Danksagung. Vladimir Vapnik und Hanspeter Mallot sei für Zusammenarbeit und Diskussionen herzlich gedankt. Ulrike Kappler, Matthias Franz und Heinrich Bülthoff danke ich für die kritische Durchsicht des Manuskripts.

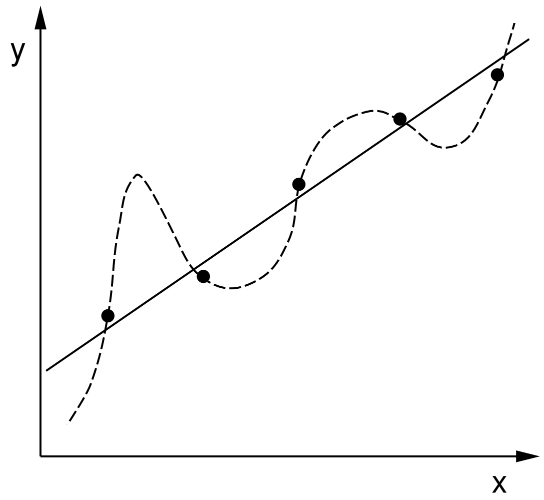

Abbildung 0.1: Aus einer gegebenen Menge von Beispielen (im Bild: schwarze Punkte) soll ein unbekannter funktionaler Zusammenhang geschätzt werden. Welche der beiden abgebildeten Hypothesen scheint plausibler?

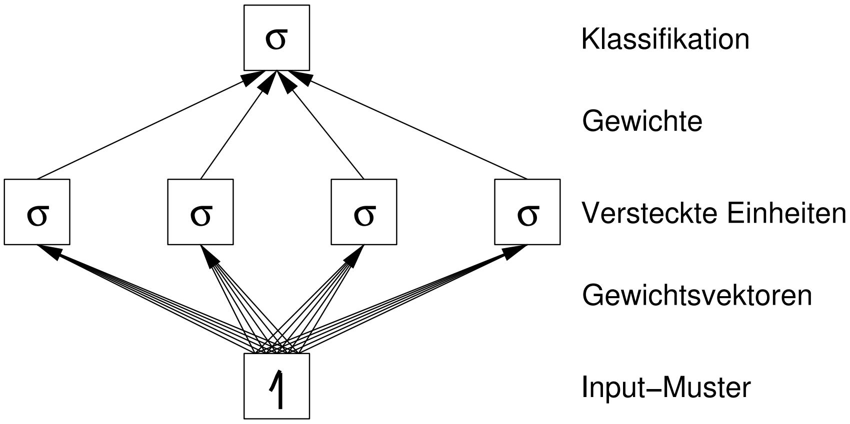

Abbildung 0.2: Zweischichtiges Perzeptron zur Klassifikation von Ziffern. Die Funktionen σ stehen für gewichtete Summation des Inputs, gefolgt von der Subtraktion eines Schwellwertes und der Anwendung einer Sigmoidfunktion (einer monotonen Funktion mit $\sigma(\pm\infty) = \pm 1$). In der obersten Schicht verwendet man für σ die Stufenfunktion sgn ($\text{sgn}(z) = 1$ für $z > 0$, $\text{sgn}(z) = -1$ sonst).

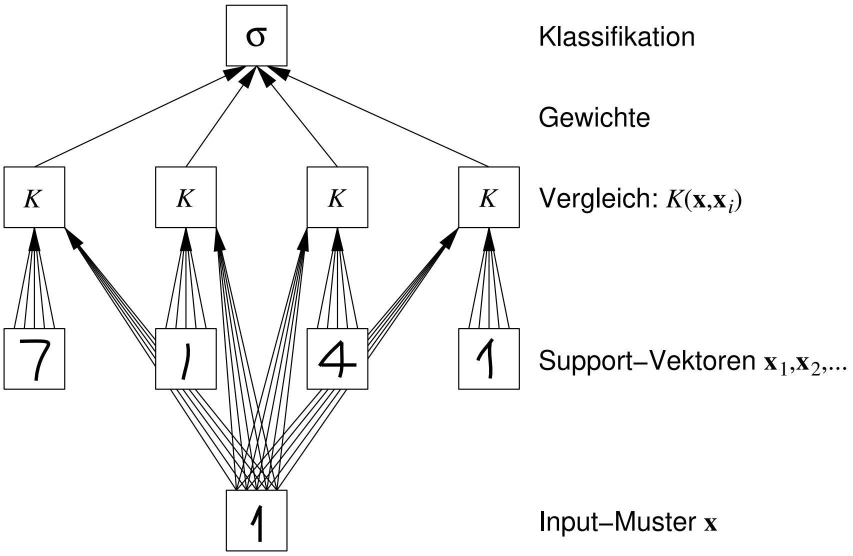

Abbildung 0.3: Support–Vektor–Maschine zur Klassifikation von Ziffern. Während des Lernprozesses werden automatisch *Support–Vektoren* aus der Trainingsmenge extrahiert. Die Funktion K wird vor dem Lernprozeß gewählt; durch geeignete Wahl lassen sich beispielsweise zweischichtige Perzeptrons (s.o.) implementieren. In diesem Fall fungieren die Support–Vektoren als Eingangsgewichte. Andere mögliche Wahlen von K führen zu Radialbasisfunktionen–Netzen und polynomialen Klassifikatoren. Man kann zeigen, daß die Wahl eines geeigneten K der Abbildung der Muster in einen höherdimensionalen Raum mit nachfolgender linearer Separation entspricht. (Definition von σ wie in Abbildung 2.)

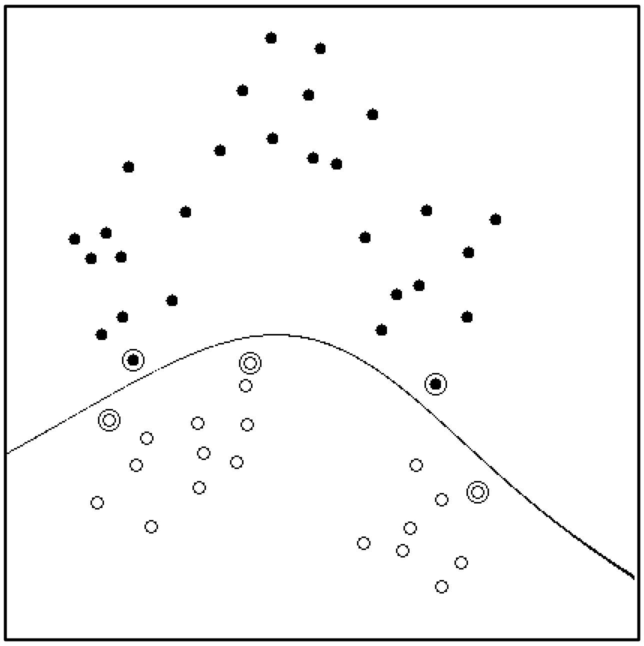

Abbildung 0.4: Eine Entscheidungsfunktion, die zwei Klassen von zweidimensionalen Mustern (dargestellt als Scheiben bzw. Kreise) separiert. Verwendet wurde eine Support–Vektor–Maschine mit Radialbasisfunktionen $K(\mathbf{x}, \mathbf{x}_i) = \exp(-\|\mathbf{x} - \mathbf{x}_i\|^2)$ (vgl. Abbildung 3). Die Support–Vektoren (eingekreist) sind charakteristisch für das zu lösende Klassifikationsproblem.

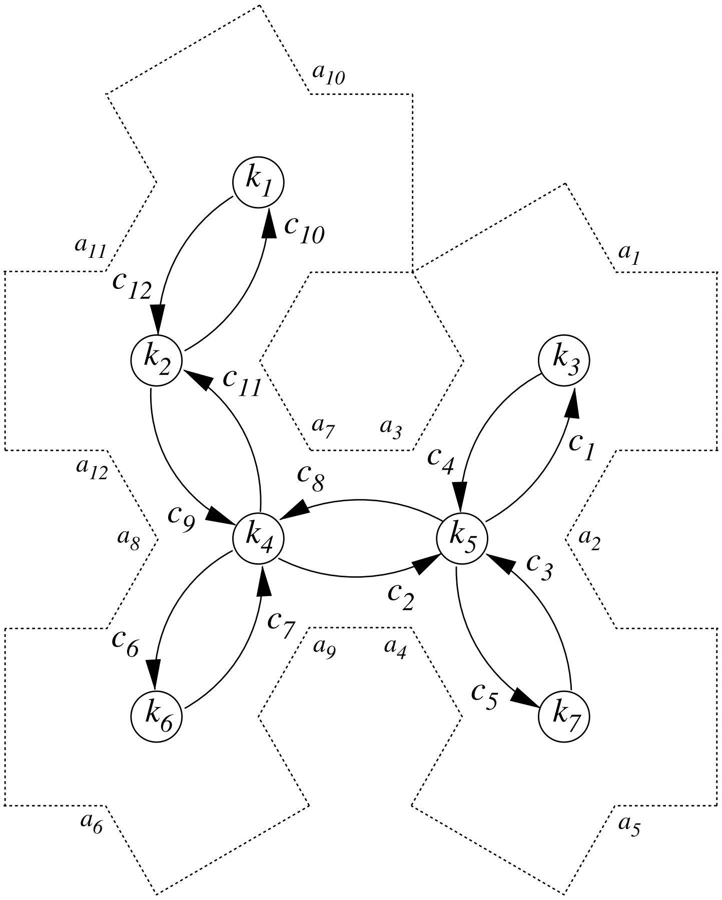

Abbildung 0.5: Einfaches Labyrinth mit *Knoten* $k_1, \ldots, k_7$ und gerichteten *Korridoren* $c_1, \ldots, c_{12}$. Zu jedem Korridor c_i gibt es eine *Ansicht* a_i $(i = 1, \ldots, 12)$ die sichtbar ist, während der Korridor passiert wird. Wie angedeutet, könnte es sich um an den gegenüberliegenden Wänden angebrachte Bilder handeln; alternativ kann man sich die Ansichten auch als die Gesamtheit der visuellen Information vorstellen, die entlang des Korridors aufgenommen wird. Das vorliegende Labyrinth besteht aus ternären Knoten; das Repertoire möglicher Bewegungsentscheidungen umfaßt *links, rechts* und *zurück*. Allgemeine Labyrinthe mit Kreuzungen von mehr als drei Korridoren können durch die Einführung von Kreisverkehren auf die vorliegende Form gebracht werden.

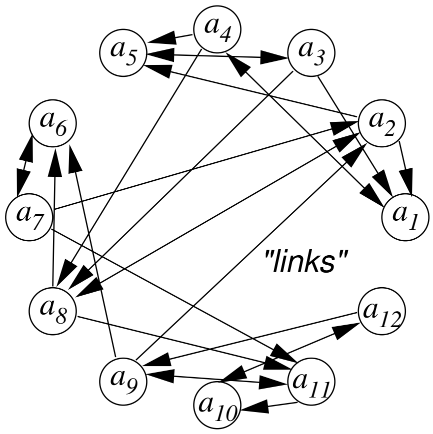

Abbildung 0.6: Ansichtsgraph zu dem Labyrinth in Abbildung 5. Verbindungen zwischen den Ansichten $a_1, \ldots, a_{12}$ entsprechen möglichen Sequenzen von Labyrinthkorridoren $c_1, \ldots, c_{12}$. Zu jeder gerichteten Verbindung gehört eine eindeutige Bewegunsentscheidung, die diese Sequenz von Ansichten erzeugt (nur eine davon ist dargestellt).

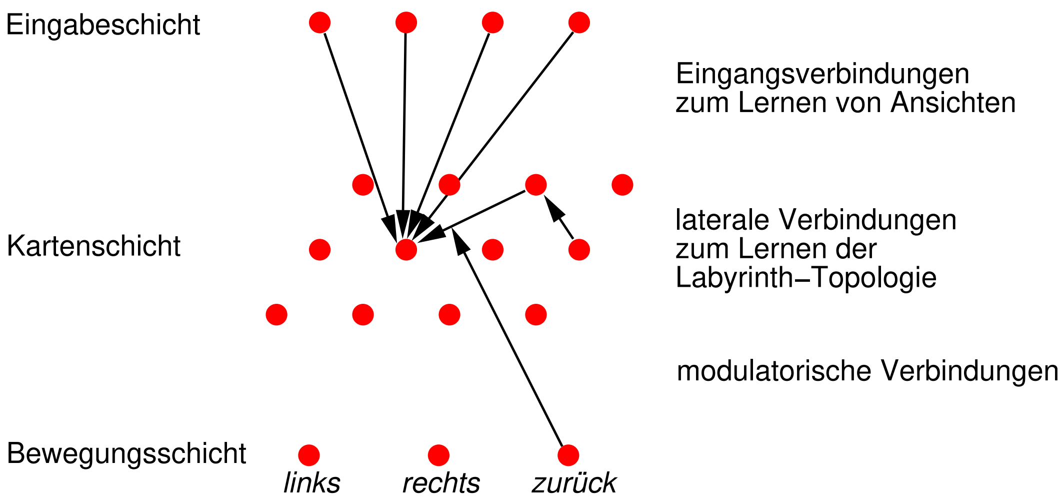

Abbildung 0.7: Architektur des Neuronalen Netzes zum Erlernen des Ansichtsgraphen. Das Netz besteht aus *Zellen* und *Verbindungen*. Der Zustand der Zellen ist durch *Aktivitäten* gekennzeichnet; die Verbindungen haben *Gewichte*, die beim Lernen verändert werden. Die aktuelle Aktivität einer Zelle berechnet sich aus der gewichteten Summe der vorigen Aktivitäten aller mit ihr verbundenen Zellen durch Anwendung einer nichtlinearen Funktion. Ansichten werden in Form von niedrigdimensionalen Vektoren auf die *Eingabeschicht* gegeben und über adaptive Verbindungen auf die *Kartenschicht* projiziert. Dort spezialisieren sich einzelne Zellen auf bestimmte Ansichten, indem in jedem Zeitschritt die Eingangsgewichte der am stärksten erregten Zelle verändert werden; die Labyrinth–Topologie wird in Form von lateraler Konnektivität codiert. Ein Satz von *Bewegungszellen* hat über modulatorische Verbindungen Einfluß auf die laterale Konnektivität (siehe Text).

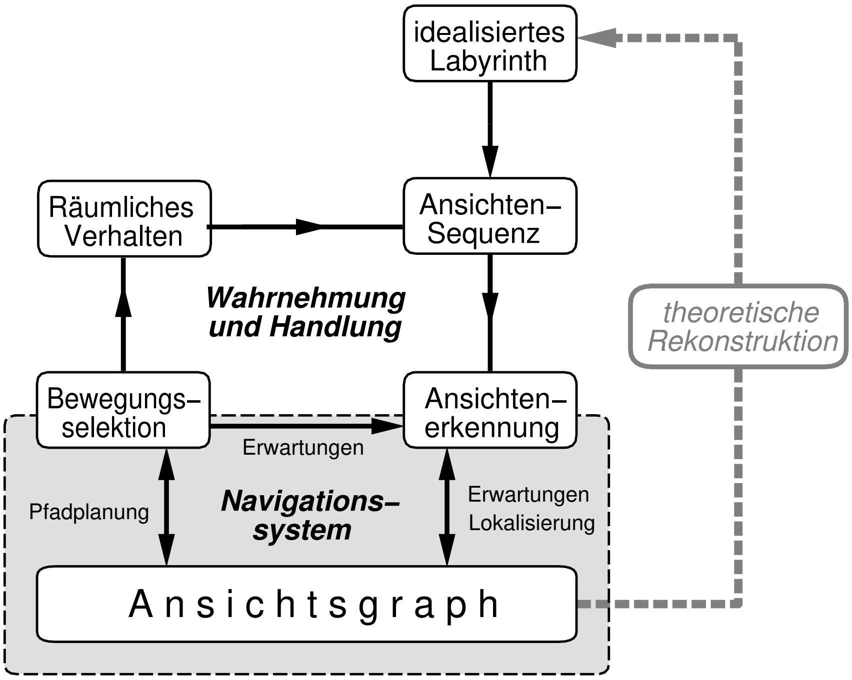

Abbildung 0.8: Der Zyklus aus Wahrnehmung und Handlung für das Ansichtsgraph–Modell. Kappt man den externen Input der Ansichtenerkennung, so genügen *Erwartungen*, um die korrekten Aktivitätsmuster in der den Ansichtsgraphen codierenden Kartenschicht des Neuronalen Netzes zu erzeugen.