Kapitel MK:II

II. Wissensrepräsentation

- Wissensrepräsentation in der Klassifikation
- Symbolisch versus subsymbolisch

- Problemlösungswissen
- Kennzeichen von Problemlösungswissen
- Prinzipien wissensbasierter Systeme
- Expertensysteme
- Problemklassen für Expertensysteme
- Erstellung wissensbasierter Systeme

©STEIN 2023

Wissensrepräsentation in der Klassifikation

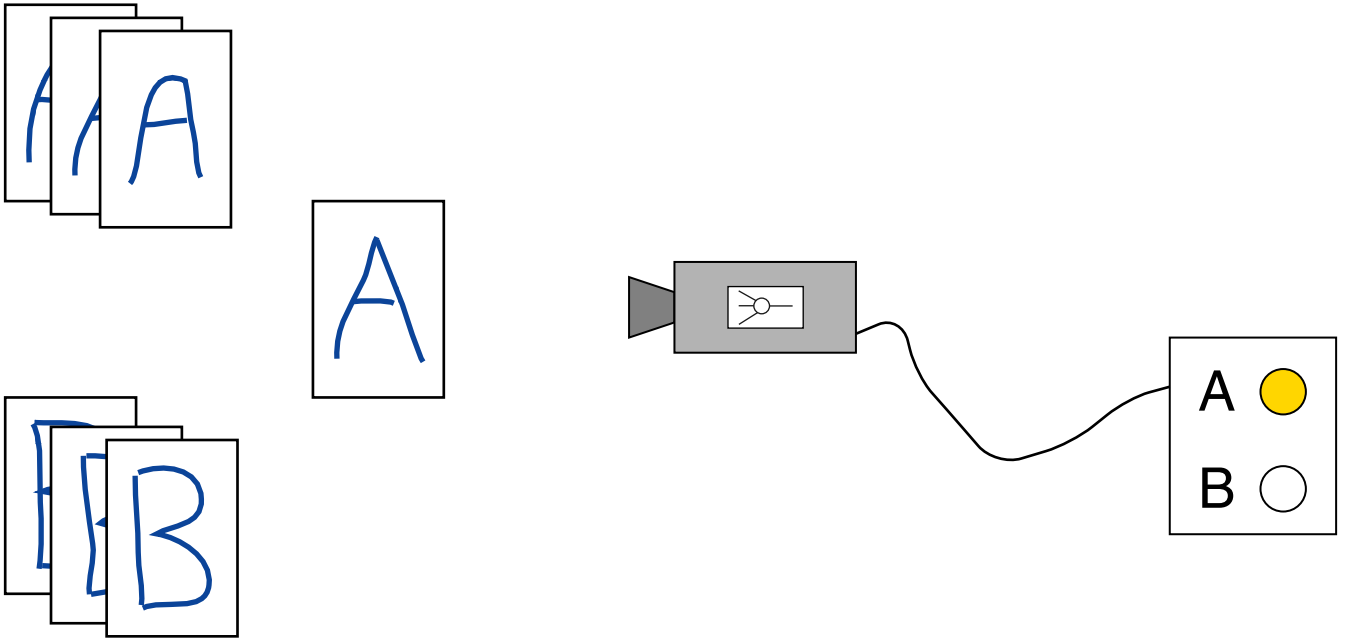

Kodierung der Buchstaben:

- Charakterisierung anhand diskriminierender Merkmale.
  (Kreuzungspunkte, spitzester Winkel, längste Kante, ...)

- Klassenzugehörigkeit als weiteres Merkmal:
  Beispiele der Menge A (B) erhalten die 1 (0) als Klassenmerkmal.

©STEIN 2023

Wissensrepräsentation in der Klassifikation

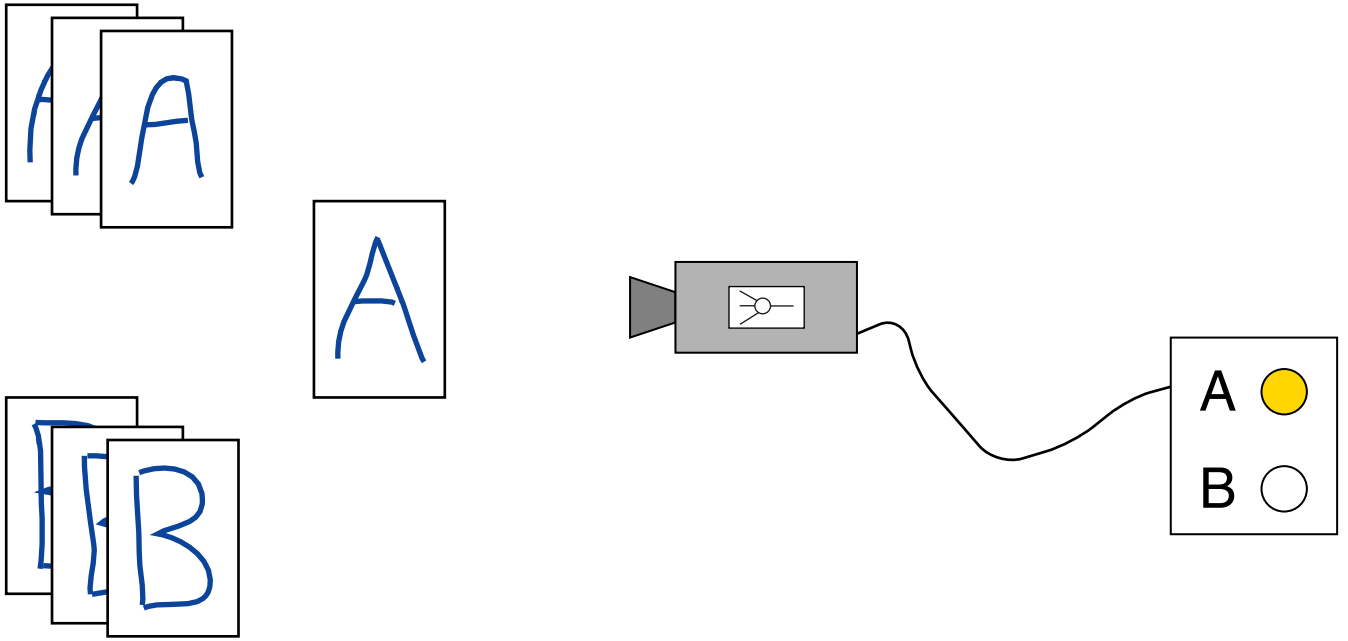

Kodierung der Buchstaben:

$$\underbrace{\begin{pmatrix} x_{1_1} \\ x_{1_2} \\ \vdots \\ x_{1_p} \end{pmatrix} \quad \cdots \quad \begin{pmatrix} x_{k_1} \\ x_{k_2} \\ \vdots \\ x_{k_p} \end{pmatrix}}_{\text{Klasse } A \ \simeq 1} \qquad \underbrace{\begin{pmatrix} x_{l_1} \\ x_{l_2} \\ \vdots \\ x_{l_p} \end{pmatrix} \quad \cdots \quad \begin{pmatrix} x_{m_1} \\ x_{m_2} \\ \vdots \\ x_{m_p} \end{pmatrix}}_{\text{Klasse } B \ \simeq 0}$$

©STEIN 2023

Wissensrepräsentation in der Klassifikation

(a) Kodierung des Klassifikationswissens durch Regeln

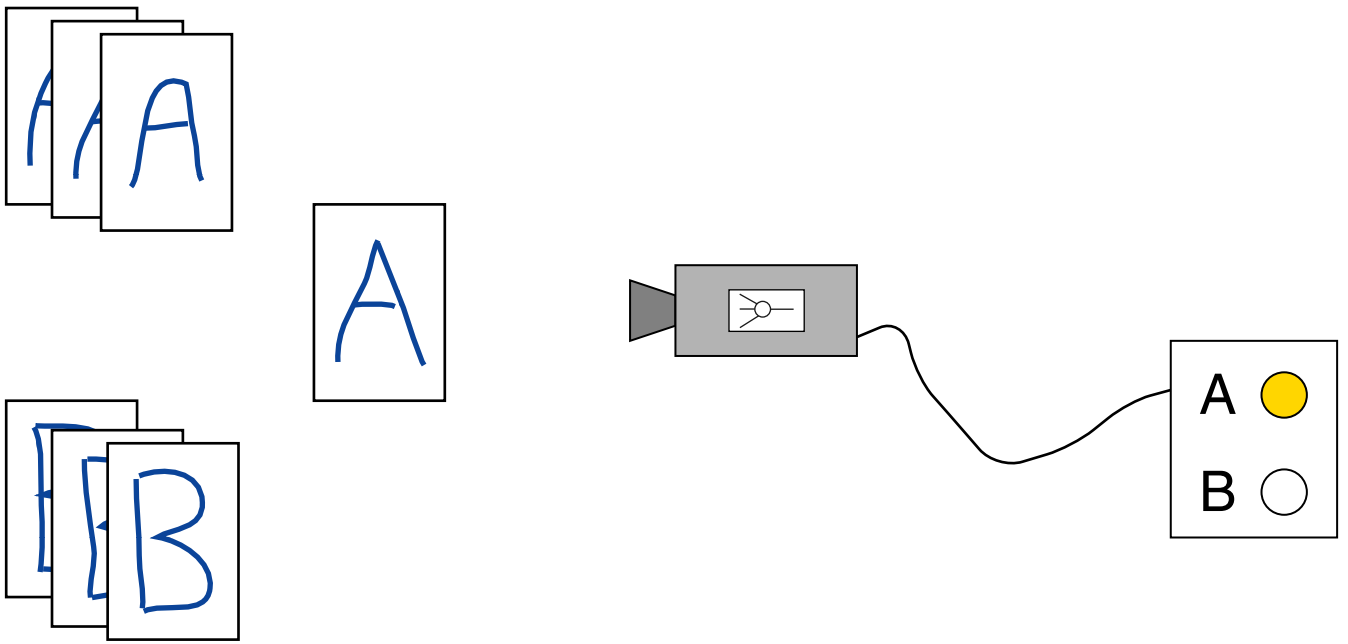


```
IF spitzester_Winkel < 40 THEN A  CONFIDENCE 0.6

IF Anzahl_Kreuzungspunkte > 3 THEN B  CONFIDENCE 0.7

...
```

Regelverarbeitung: Forward-Chaining, Backward-Chaining, Konfidenzverrechnung

© STEIN 2023

Wissensrepräsentation in der Klassifikation

(b) Erlernung des Klassifikationswissens

- Die Beispiele werden einem Perzeptron präsentiert.
- Das Perzeptron berechnet einen Wert, der als Klassenzugehörigkeit interpretiert wird.

Rosenblatt's Perzeptron:

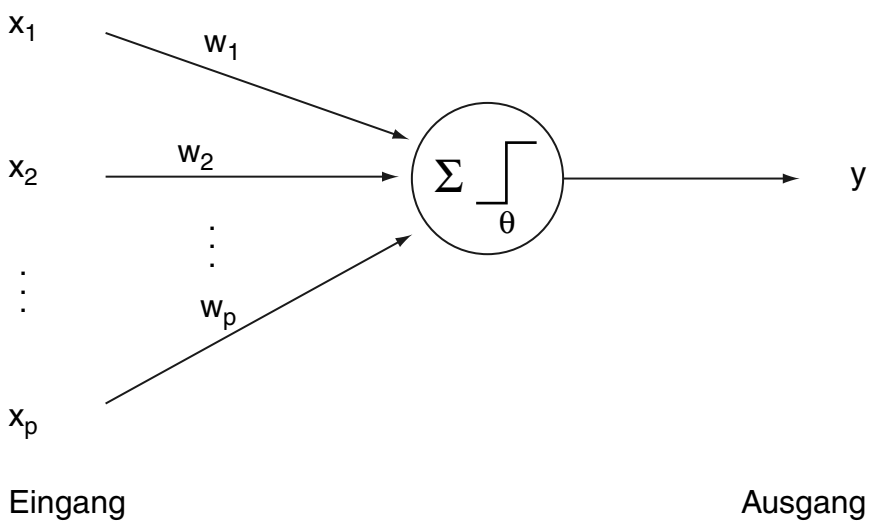

Die Natur ist unser Vorbild für diese Art des Wissenserwerbs.

© STEIN 2023

Wissensrepräsentation in der Klassifikation

Berechnung im Perzeptron

Falls $\sum_{i=1}^{p} w_i x_i \geq \theta$ dann $y = 1$.

Falls $\sum_{i=1}^{p} w_i x_i < \theta$ dann $y = 0$.

Abkürzend: $\sum_{i=1}^{p} w_i x_i = \mathbf{w}^T \mathbf{x}$, auch geschrieben als $\langle \mathbf{w}, \mathbf{x} \rangle$

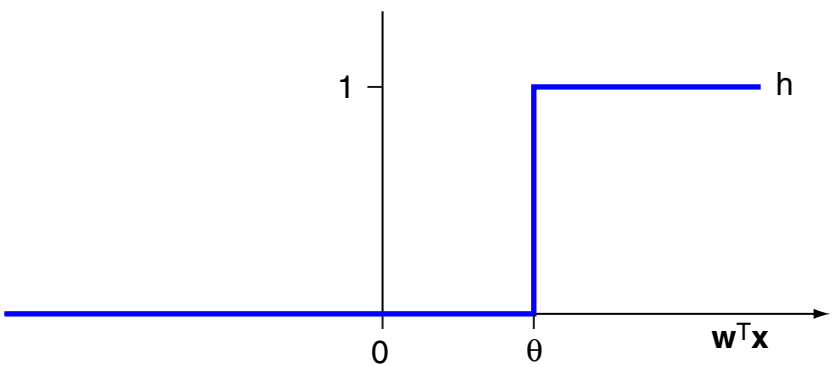

©STEIN 2023

Wissensrepräsentation in der Klassifikation

Berechnung im standardisierten Perzeptron

$$y = h\Big(\sum_{i=1}^{p} w_i x_i - \theta\Big) = h\Big(\sum_{i=0}^{p} w_i x_i\Big) \quad \text{mit} \quad w_0 = \theta \quad \text{und} \quad x_0 = -1$$

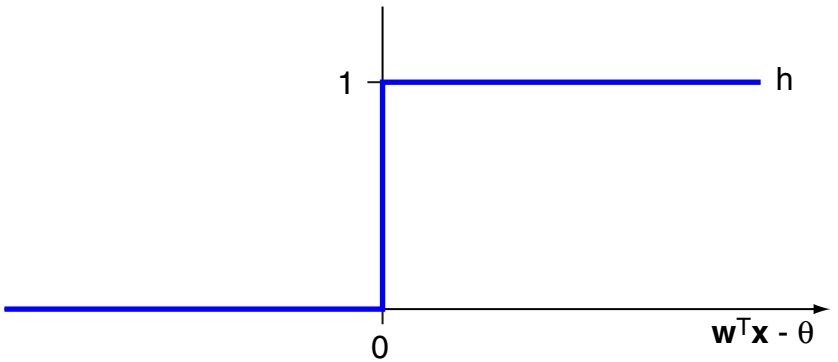

©STEIN 2023

Wissensrepräsentation in der Klassifikation

Präsentation von Beispielen dem Perzeptron:

- Folge $\mathbf{x}(0), \mathbf{x}(1), \mathbf{x}(2), \mathbf{x}(3), \ldots$
- Berechnung von $y(t) = \mathbf{w}^T(t)\mathbf{x}(t)$

Lernregel:

- Richtige Klassifikation: Gewichte bleiben unverändert.
- Falsche Klassifikation von Beispiel aus A: Gewichte werden erhöht.
- Falsche Klassifikation von Beispiel aus B: Gewichte werden verringert.

Charakteristika des Lernprozesses:

- Das Lernen ist *überwacht* (wir kennen das Ergebnis).
- Nur am Fehler beteiligte Gewichte werden verändert:
  Hebb'sches Lernen [Donald Hebb, 1949]

©STEIN 2023

Wissensrepräsentation in der Klassifikation

Perzeptron-Lernalgorithmus

Eingabe. Menge $\mathbf{D}$ von Beispielvektoren $(x_1, \ldots, x_p, d)^T$, $x_i \in \mathbf{R}$, $d \in \{0, 1\}$, Anpassungsfaktor $\eta \in [0; 1]$

Ausgabe. Gewichtsvektor $\mathbf{w} = (\theta, w_1, \ldots, w_p)^T$, $w_i \in \mathbf{R}$

1. Initialisierung: $\mathbf{w}(0) = \Big(\theta(0), w_1(0), \ldots, w_p(0)\Big)^T$, $t = 0$
2. Solange bis Konvergenz von $\mathbf{w}$ erreicht oder t_{max} überschritten
   (a) Wähle einen Vektor aus $\mathbf{D}$ und berechne Ausgang $y(t)$

   $$y(t) = h\Big(\sum_{i=0}^{p} w_i(t) x_i(t)\Big), \quad \forall t : x_0(t) = -1$$

   (b) Falls $y(t) = d(t)$: $\mathbf{w}(t+1) = \mathbf{w}(t)$

   Falls $y(t) = 0 \wedge d(t) = 1$: $\mathbf{w}(t+1) = \mathbf{w}(t) + \eta \mathbf{x}(t)$

   Falls $y(t) = 1 \wedge d(t) = 0$: $\mathbf{w}(t+1) = \mathbf{w}(t) - \eta \mathbf{x}(t)$

   (c) $t = t + 1$

©STEIN 2023

Wissensrepräsentation in der Klassifikation

Darstellung der Objekte im Merkmalsraum

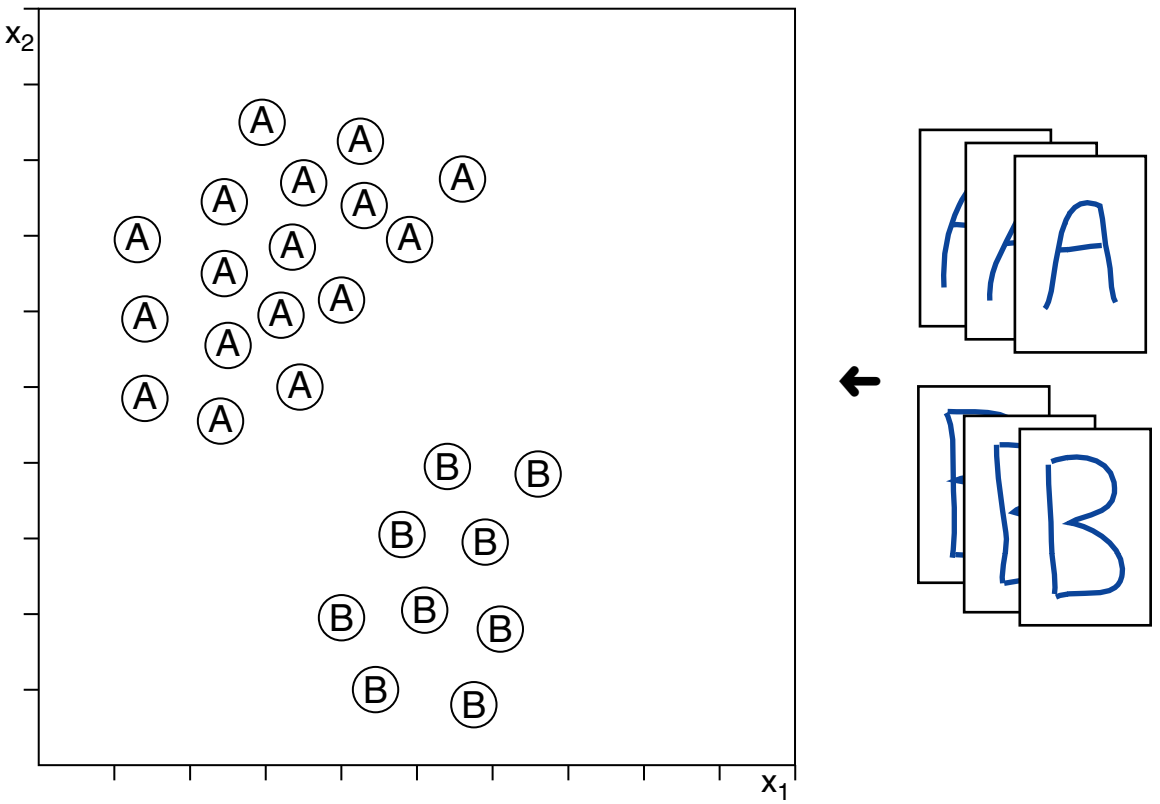

©STEIN 2023

Wissensrepräsentation in der Klassifikation

Anpassung des Gewichtsvektors

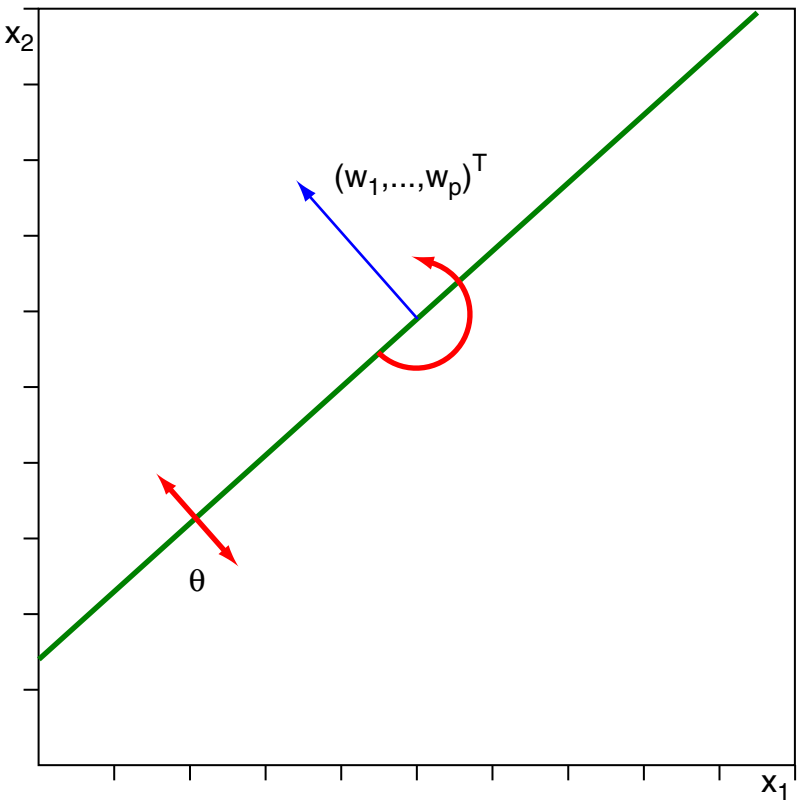

Bemerkung:

Ein Perzeptron definiert eine Gerade (Hyperebene) senkrecht (normal) zu $(w_1, \ldots, w_p)^T$.
θ beschreibt die Verschiebung der Geraden (Hyperebene) senkrecht zu $(w_1, \ldots, w_p)^T$.

©STEIN 2023

Wissensrepräsentation in der Klassifikation

Illustration des Perzeptron-Lernalgorithmus

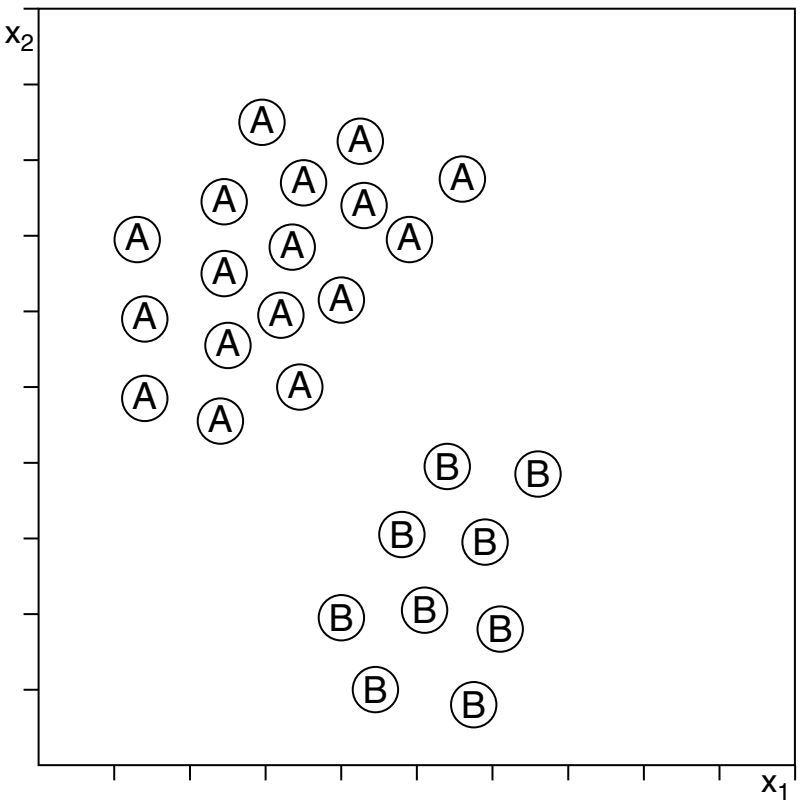

© STEIN 2023

Wissensrepräsentation in der Klassifikation

Illustration des Perzeptron-Lernalgorithmus

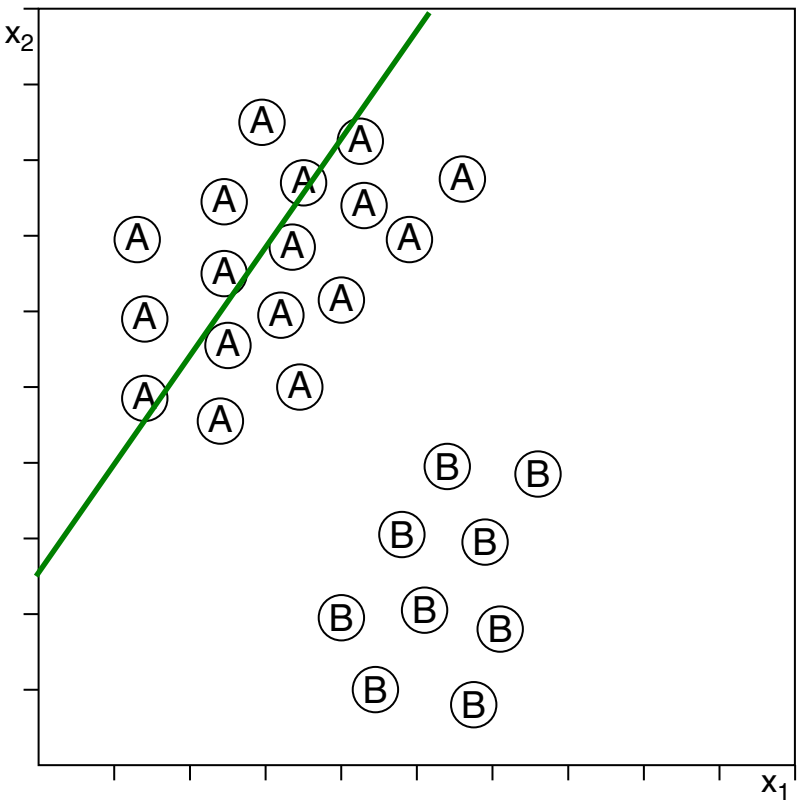

© STEIN 2023

Wissensrepräsentation in der Klassifikation

Illustration des Perzeptron-Lernalgorithmus

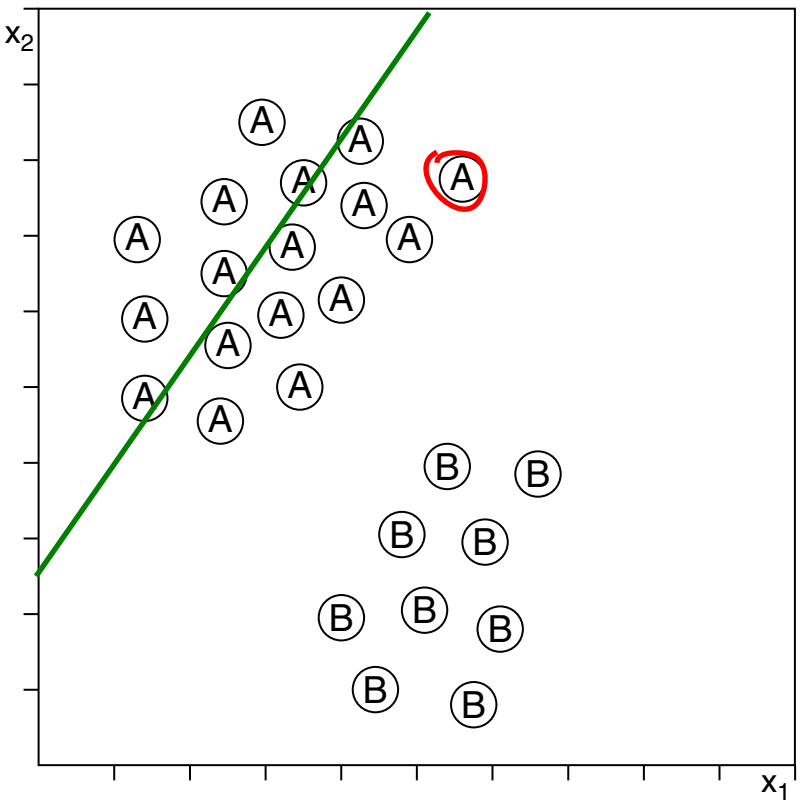

© STEIN 2023

Wissensrepräsentation in der Klassifikation

Illustration des Perzeptron-Lernalgorithmus

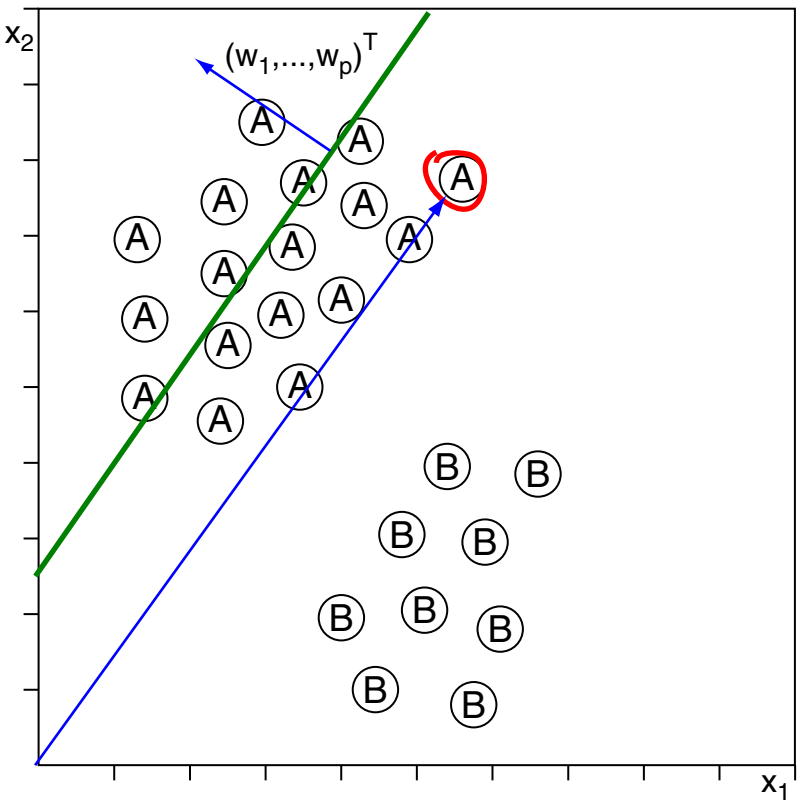

© STEIN 2023

Wissensrepräsentation in der Klassifikation

Illustration des Perzeptron-Lernalgorithmus

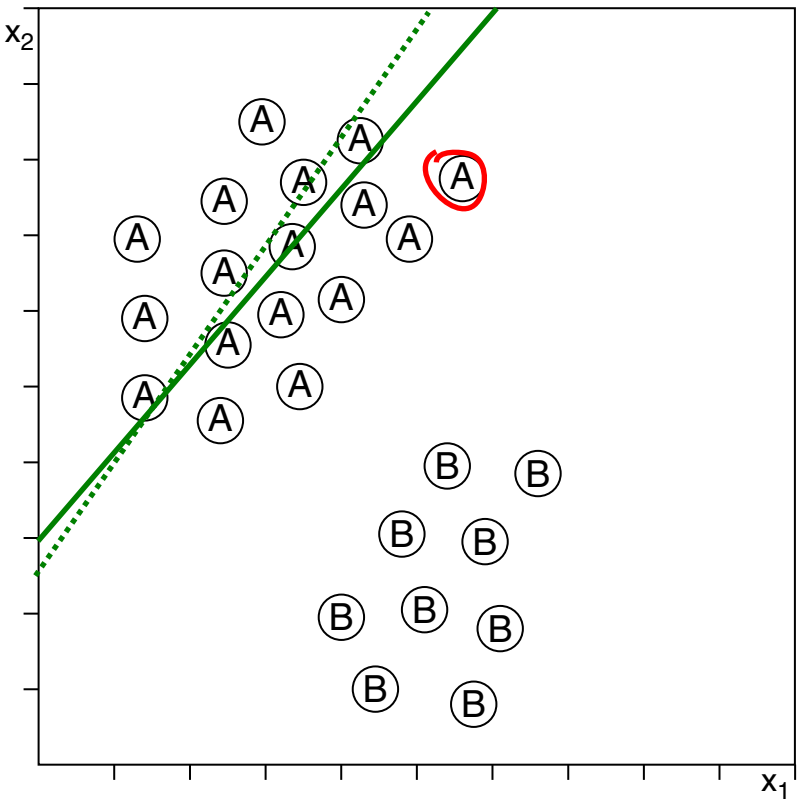

© STEIN 2023

Wissensrepräsentation in der Klassifikation

Illustration des Perzeptron-Lernalgorithmus

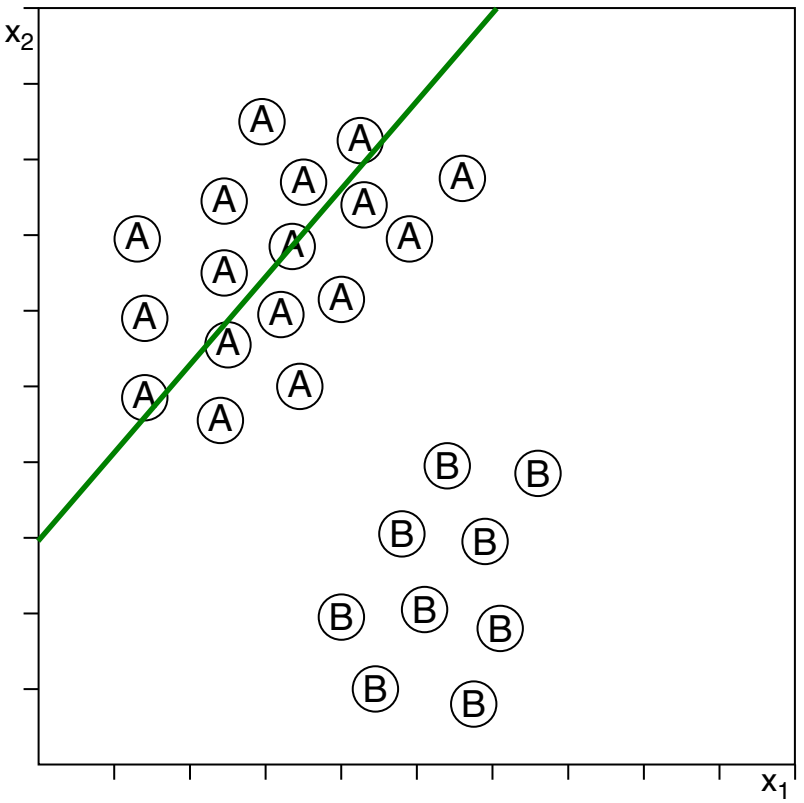

©STEIN 2023

Wissensrepräsentation in der Klassifikation

Illustration des Perzeptron-Lernalgorithmus

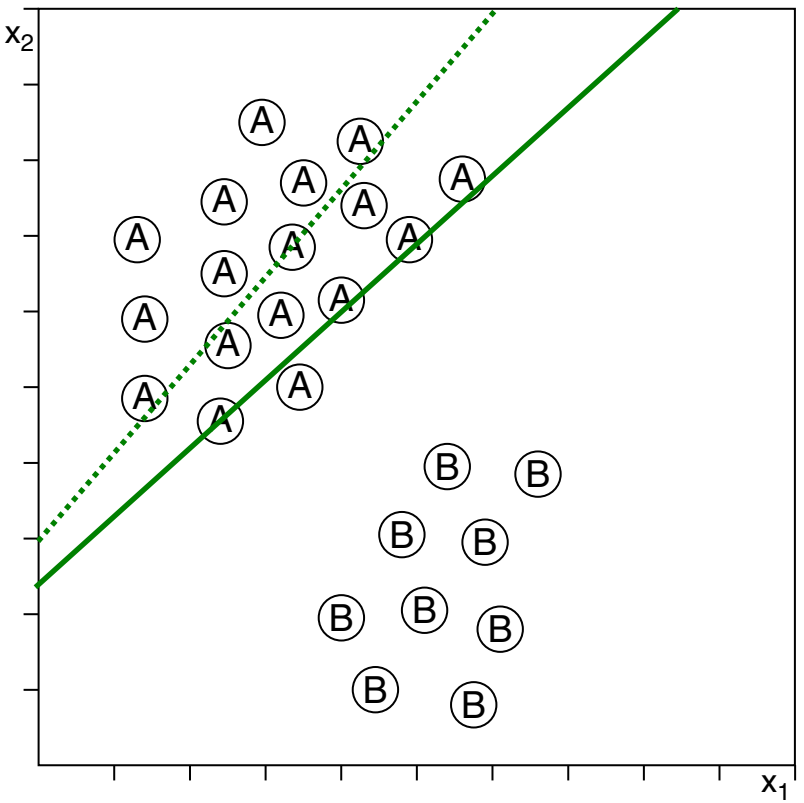

©STEIN 2023

Wissensrepräsentation in der Klassifikation

Illustration des Perzeptron-Lernalgorithmus

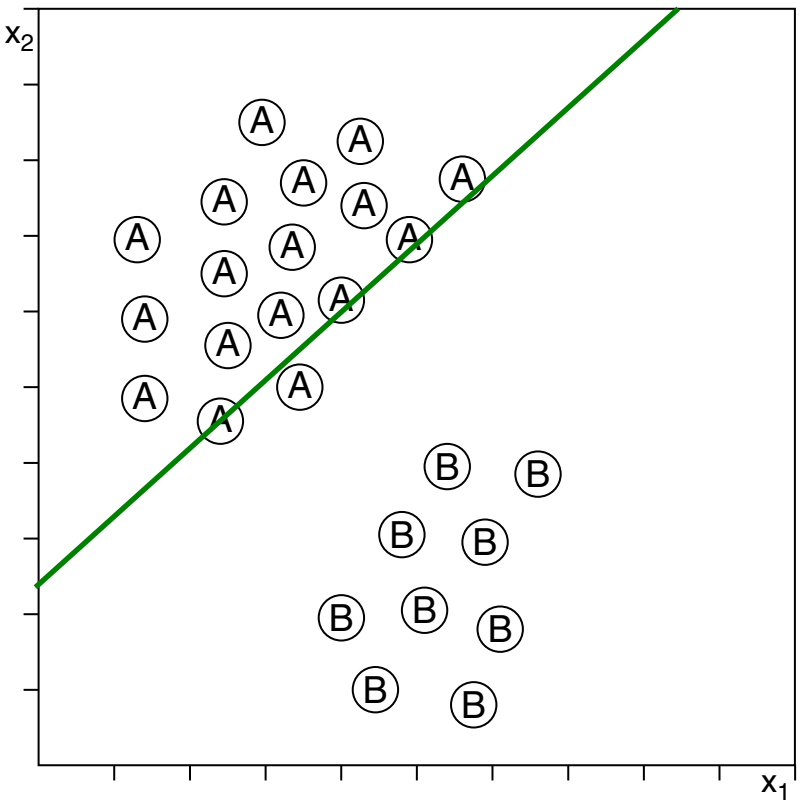

©STEIN 2023

Wissensrepräsentation in der Klassifikation

Illustration des Perzeptron-Lernalgorithmus

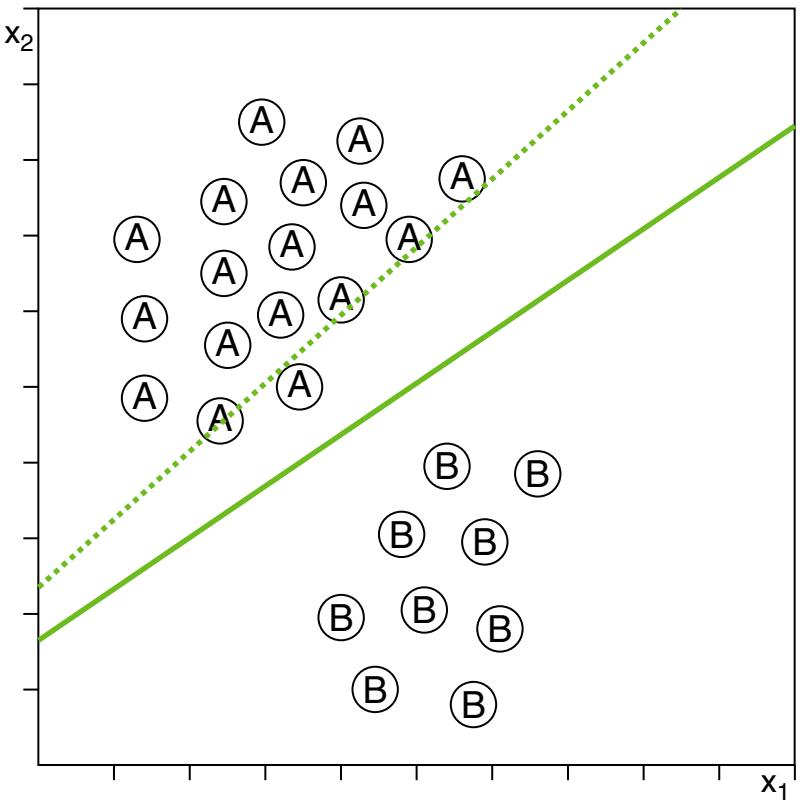

©STEIN 2023

Wissensrepräsentation in der Klassifikation

Illustration des Perzeptron-Lernalgorithmus

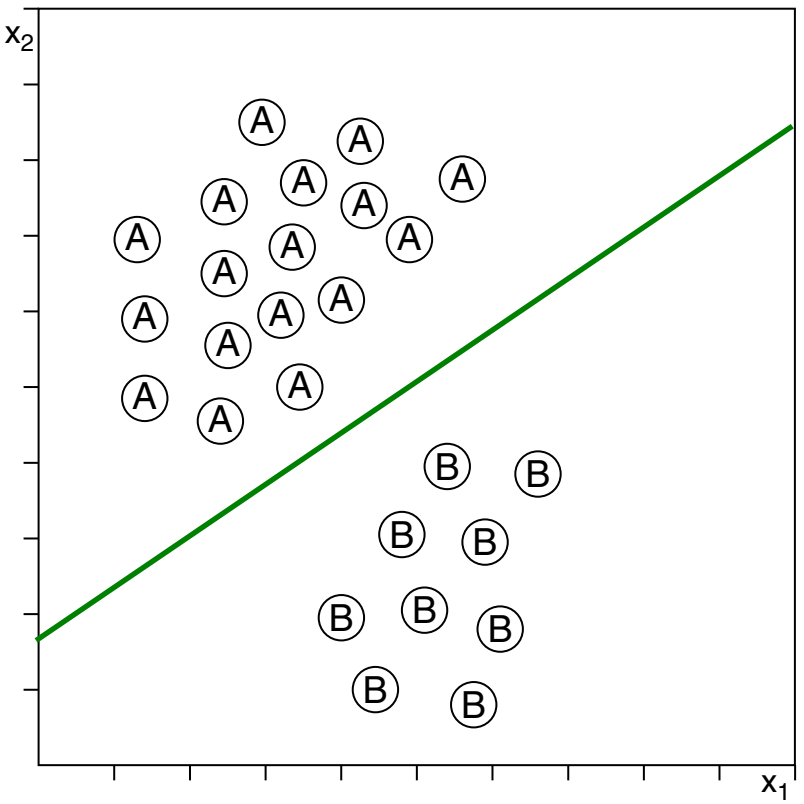

© STEIN 2023

Kapitel MK:II

II. Wissensrepräsentation

- Wissensrepräsentation in der Klassifikation
- Symbolisch versus subsymbolisch

- Problemlösungswissen
- Kennzeichen von Problemlösungswissen
- Prinzipien wissensbasierter Systeme
- Expertensysteme
- Problemklassen für Expertensysteme
- Erstellung wissensbasierter Systeme

©STEIN 2023

Symbolisch versus subsymbolisch

Zwei grundlegenden Ansätze der Wissensrepräsentation

Symbolische Modellierung/Repräsentation:

- Sprachlich fassbare elementare Einheiten, die durch Bezeichner gekennzeichnet sind.
- Kompositionale Bedeutungsbestimmung ausgehend von den Elementareinheiten („Units“) der Repräsentation. [vgl. Moeller 2002]

Subsymbolische Modellierung/Repräsentation:

- Elementareinheiten sind nicht durch Bezeichner charakterisiert.
- Repräsentation und Bedeutung ergibt sich aus dem Zusammenwirken bzw. der Überlagerung der Units der Repräsentation. [vgl. Moeller 2002]

© STEIN 2023

Symbolisch versus subsymbolisch

Definition 1 (Symbol)

Ein Symbol ist ein Gegenstand oder Vorgang, der stellvertretend für einen anderen nicht wahrnehmbaren geistigen Sachverhalt steht.

[Duden 95]

Symbol in der Informatik [vgl. Ultsch 1998]:

- Gegenstand oder Vorgang wird als Zeichen eines Alphabets interpretiert.
- Ein Zeichen, z. B. ein Buchstabe, wird dabei als atomar – d. h., als nicht weiter zerlegbar in Bestandteile, ohne dass seine Rolle als Zeichen verloren geht – angesehen.
- Der nicht wahrnehmbare geistige Sachverhalt wird als die Bedeutung (Semantik) des Zeichens angesehen.

Techniken zur Modellierung und Verarbeitung symbolisch repräsentierten Wissens:

- Logik, Regeln, Constraints, Deduktion, Inferenz-Verfahren, Constraint-Verarbeitung

©STEIN 2023

Symbolisch versus subsymbolisch

Akustische Repräsentation eines gesprochenen Symbols:

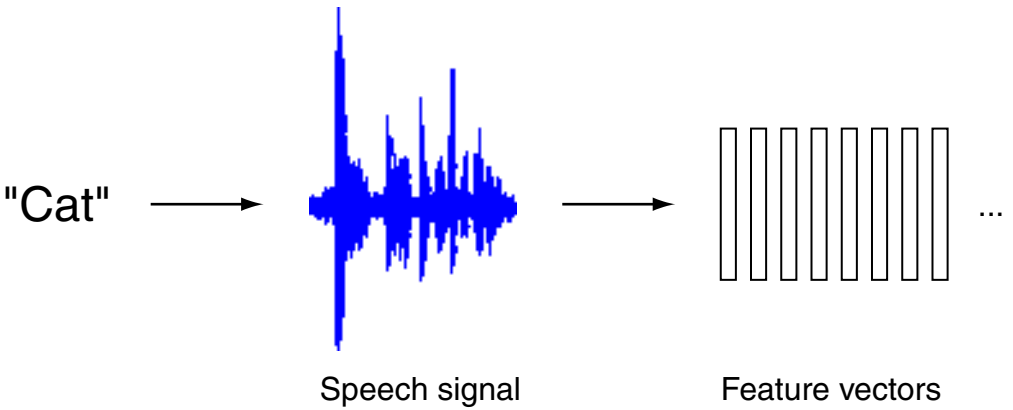

Techniken zur Modellierung und Verarbeitung subsymbolisch repräsentierten Wissens:

- neuronale Netze, genetische Algorithmen – allgemein: konnektionistische Modelle; teilweise auch Fuzzy-Reasoning

Die Änderung eines Mikrofeatures wird in der Regel keine entscheidende Auswirkung auf das repräsentierte Symbol haben.

©STEIN 2023

Symbolisch versus subsymbolisch

Beispiel: J. S. Bach, „Die Kunst der Fuge“ [(vgl. [Ultsch 1998])]

Symbolische Repräsentation (Ausschnitt aus Partitur, Symbole sind die Noten):

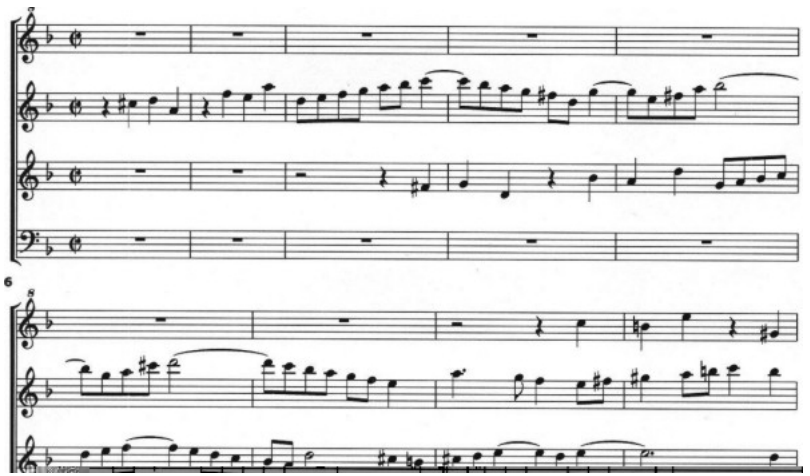

Subsymbolische Repräsentation (Zahlenfolge auf CD):

```
128 128 128 128 128 130 127 128 134 125 121 136 133 112 126 139 121 132 137 122 131 136 115 140 140 106
118 139 114 124 153 111 111 159 134 103 142 139 97 124 148 108 111 153 118 106 150 139 106 193 193 14 64
188 96 164 138 74 171 175 27 160 148 75 128 199 96 108 142 132 132 103 138 145 108 103 159 122 114 132 134
114 124 118 138 117 134 134 103 96 164 100 117 148 128 128 132 122 108 177 132 117 70 175 139 31 134 156
100 156 124 128 139 81 106 159 114 117 170 124 103 132 118 100 132 134 114 148 118 134 124 118 128 138 111
128 134 114 138 132 111 100 139 122 117 134 148 153 111 111 159 134 103 142 139 97 124 148 108 111 153 118
106 150 139 106 134 142 103 124 145 114 114 148 128 111 142 138 108 134 150 108 103 148 132 111 142 124
114 145 134 114 138 128 111 124132 134 114 124 118 138 117 134 134 103 96 164 100 117 148 128 128 132 122
64 128 118 128 134 192 111 124 128 118 90 118 188 148 86 145 170 92 79 148 171 142 118 128 159 122 68 114
166 159118 134 124 118 128 138 111 ...
```


©STEIN 2023

Bemerkungen:

- Im Kontext des Musikhörens besitzt eine einzelne Zahl für sich alleine genommen keine Bedeutung.
- Fehlerkorrektur eines CD-Spielers kann sogar sinnvolle Ergänzung vornehmen.

©STEIN 2023

Symbolisch versus subsymbolisch

Vorteile symbolischer Repräsentation:

- unmittelbare Interpretierbarkeit
- leichte explizite Analyse
- Wissensabstraktion, Formulierung von Metawissen
- Kalküle zum deduktiven Schlussfolgern

Vorteile subsymbolischer Repräsentation:

- Lernprozess einfacher organisierbar
- robuste Verarbeitung
- Generalisierbarkeit auf neue ähnliche Eingaben
- fehlertoleranter als symbolische KI-Technologien

©STEIN 2023

Bemerkungen:

- Die Berechnungsmächtigkeit der subsymbolischen KI könnte höher als bei symbolischer KI sein. Argumentation: Durch Verzicht auf das Verstehen des Lösungsweges wird eine andere, größere Klasse von Algorithmen berechenbar.

- Auch in konnektionistischen Modellen kann Wissen in symbolischer Form repräsentiert werden. Beispiel: einzelne Units (Neuronen, Gene) können eine klar definierte Bedeutung tragen.

©STEIN 2023

Symbolisch versus subsymbolisch

Erwerb neuen Wissens

Symbolische Wissensrepräsentation:

- Maschinelles Lernen setzt nur bekannte Symbole zu (Linear)kombinationen zusammen.

➜ Neues im Sinne neuer Begriffsbildungen oder Detektion von neuen Zusammenhängen sind nicht möglich.

Subsymbolische Wissensrepräsentation:

- Lernen bedeutet die Überlagerung der Repräsentationen in den Units.

➜ Subsymbolische KI-Systeme könnten wirklich Neues entdecken.

Schwerpunkt bei Expertensystemen (und insbesondere in dieser Vorlesung) ist die symbolische Repräsentation von Wissen.

© STEIN 2023

Symbolisch versus subsymbolisch

Hybride Systeme: Kombination der Paradigmen

1. „Combined Intelligent Systems“
   - Systeme, die neuronale Netze als Werkzeug für die Symbolverarbeitung benutzen (top-down-approach).
   - Neuronale Netze, die symbolische KI-Konzepte benutzen, um die subsymbolische Verarbeitung zu unterstützen (bottom-up-approach).

2. „Transformational Intelligent Systems“
   Symbolische oder subsymbolische Konzepte werden benutzt, um die eine Repräsentation in die andere umzuwandeln.

3. „Coupled Intelligent Systems“
   Module mit symbolischen und subsymbolischen Konzepten werden kombiniert. Die Module sind unabhängig voneinander und spielen ihre jeweiligen Stärken aus.

[Stamou et al. 1999]

©STEIN 2023

Symbolisch versus subsymbolisch

Hybride Systeme: Kombination der Paradigmen

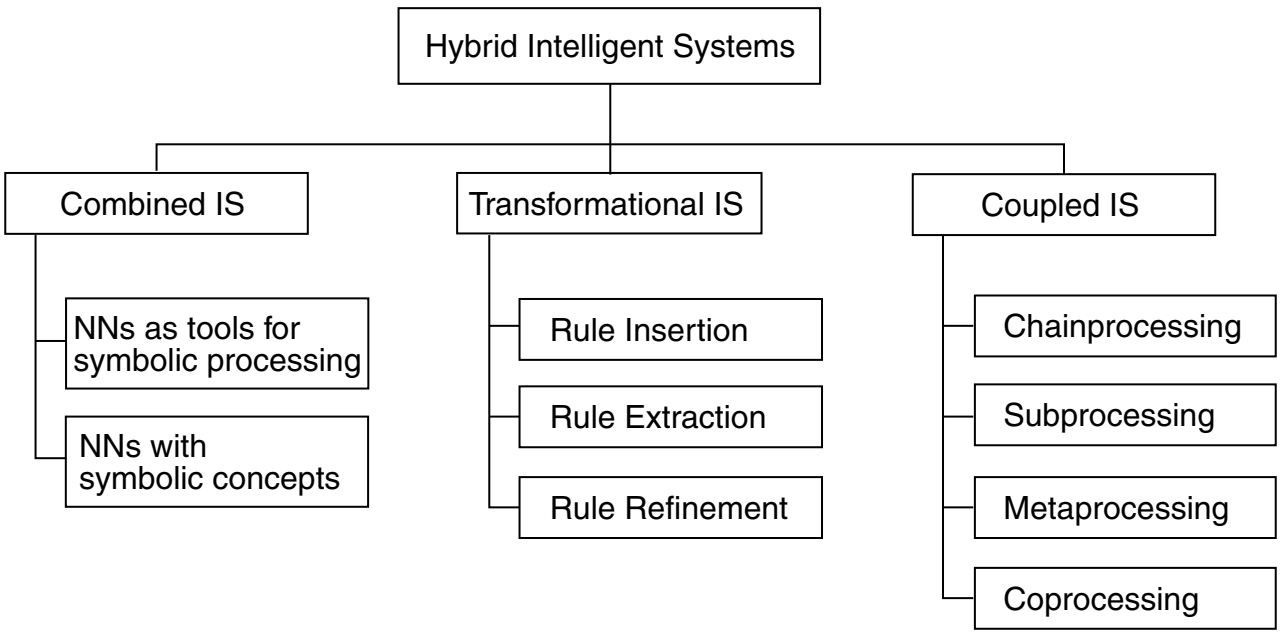

©STEIN 2023

Marvin Minsky

©STEIN 2023