

Fallbasiertes Schließen, FBS bzw. CBR = Case Based Reasoning

1. Grundidee: Handeln auf der Basis von Erfahrungen

Jede von mir gelöste Aufgabe wurde zum Muster, welches ich im weiteren für die Lösung anderer Aufgaben benutzte.

DESCARTES

Der Mensch hat dreierlei Wege klug zu handeln:

Erstens durch **Nachdenken**,

– das ist der edelste,

zweitens durch **Nachahmen**,

– das ist der leichteste,

und drittens durch **Erfahrung**,

– das ist der bitterste.

KONFUZIUS

Alles Wissen stammt aus Erfahrung.

KANT

Problem:

Das Bild des Beamers ist unscharf und flackert

Lösungsversuche:

- ... adjustieren gemäß Angaben der Bedienungsanleitung
- ... Zeilenfrequenzen ändern
- ... Auflösung ändern
- ... Kabel untersuchen

Problem:

Das Bild des Beamers ist unscharf und flackert

Lösungsversuche:

... adjustieren gemäß Angaben der Bedienungsanleitung

... Zeilenfrequenzen ändern

... Auflösung ändern

... Kabel untersuchen

... **Stecker umdrehen!**

Fall = Problem + Lösung: $\boxed{P} + \boxed{L}$

\boxed{P} = $\boxed{\text{Das Bild des Beamers ist unscharf und flackert.}}$


\boxed{L} = $\boxed{\text{Stecker umdrehen.}}$

Grundschema (naive Sicht):

Neues Problem P : unbekannte Lösung L .

Altes Problem P' : bekannte Lösung L' .

\Rightarrow Alte Lösung L' an Problem P anpassen



Ausgangs-Hypothese (später genauer untersuchen):

„Ähnliche Fälle haben ähnliche Lösungen“

A-posteriori-Ähnlichkeit:

$$\boxed{L_1} \sim \boxed{L_2} \Rightarrow \boxed{P_1} \sim \boxed{P_2}$$

i.a. nicht vernünftig realisierbar

(Bsp.: gleiche Strafe für unähnliche Taten).

Umkehrung:

$$\boxed{L_1} \sim \boxed{L_2} \Leftarrow \boxed{P_1} \sim \boxed{P_2}$$

Notwendig bei normativen Problemen (Rechtsprechung).

Falls nicht erfüllt: Ähnlichkeit falsch definiert?

Extremfall: Ähnlichkeit = Identität

Später: graduelle Ähnlichkeit (Ähnlichkeitsmaße)

Kognitiver Aspekt der KI

Modellieren der natürlichen Intelligenz, Imitation, Experimente

Technischer Aspekt der KI

Automatisierung geistiger Prozesse, „Intelligente“ Maschinen, Programme, ...

KI-Ansätze:

- Logik
- Stukturierte Repräsentationen
- Regeln
- Constraint Propagation
- Suchverfahren
- Neuronale Netze
- ...
- Fallbasiertes Schließen

Lösungen „from scratch“ ?

Kognitive Adäquatheit.

Experten-Wissen:

Studium + Erfahrung

Human experts are not systems of rules,
they are libraries of experiences.

RIESBECK/SCHANK

„Allgemeines“ Wissen : Lehrbücher, Regeln, Gesetze, Normen, ...

„Spezielles“ Wissen : Erfahrungen: „Fälle“

Ich hatte da einen Fall ...

In solchen Fällen muß man ...

- Medizin
- Rechtssprechung
- Technische Diagnose
- Konstruktion (\Rightarrow „Motorkutsche“)
- ...
- Kreativität, Intuition, ...

Denken in Fällen

zur Erklärung : Fallbeispiel

ein Beispiel sagt mehr als tausend Erklärungen

zur Aufstellung von Regeln – Generalisierung :

Experimente (Fälle) zur Erzeugung, Überprüfung

Regelfall, allgemeiner, abstrakter, typischer Fall, ...

zur Eingrenzung von Regeln :

Ausnahmefall, Sonderfall, Einzelfall,

zur Übertragung – Analogien :

analoger Fall, Vorbild, ...

zum Lernen : Probefall, Fehlerfall, ...

aus Fehlern lernen

Unterschiedliche Abstraktionsebenen:

„typischer Fall“ als konkretes Beispiel („Element“) für einen „Regelfall“ („Menge“).

Generalisierung, Abstraktion:

Übergang zu allgemeinen Aussagen (z.B. Regeln)

daneben stets: *Ausnahmefall, Sonderfall, Einzelfall,*

Fälle in der Umgangssprache:

Ausnahmefall,

Spezialfall,

Parallelfall,

Einzelfall,

Zwischenfall,

Vorfall,

Bedarfsfall,

Wiederholungsfall,

Präzedenzfall,

Grenzfall,

Glücksfall,

Zweifelsfall,

Ausfall,

Zufall,

Wasserfall,

Unfall,

Überfall,


Anfall,

Einfall,

Sündenfall,

Abfall

Aufgabe: Figur in 4 kongruente Teile zerlegen



Container: Grundbestandteile eines Fallbasierten Systems:

- Vokabular (Falldatenbasis)
- Ähnlichkeit von Fällen
- Auswahlmechanismus (Retrieval)
- Transformation: Anpassung von Lösungen

„**Ähnlich**“ oder „analog“:

Fallbasiertes Schließen: innerhalb einer Domäne

Analoges Schließen: Übertragung auf andere Domäne

Klassische **Falldarstellung**: Problem + Lösung (+ Erklärung) (+ Bewertung)

Attribut-Werte-Paare, Texte, Grafiken, Bilder, ...

Datenbanken, Protokolle, Log-Files, Notizen, ...

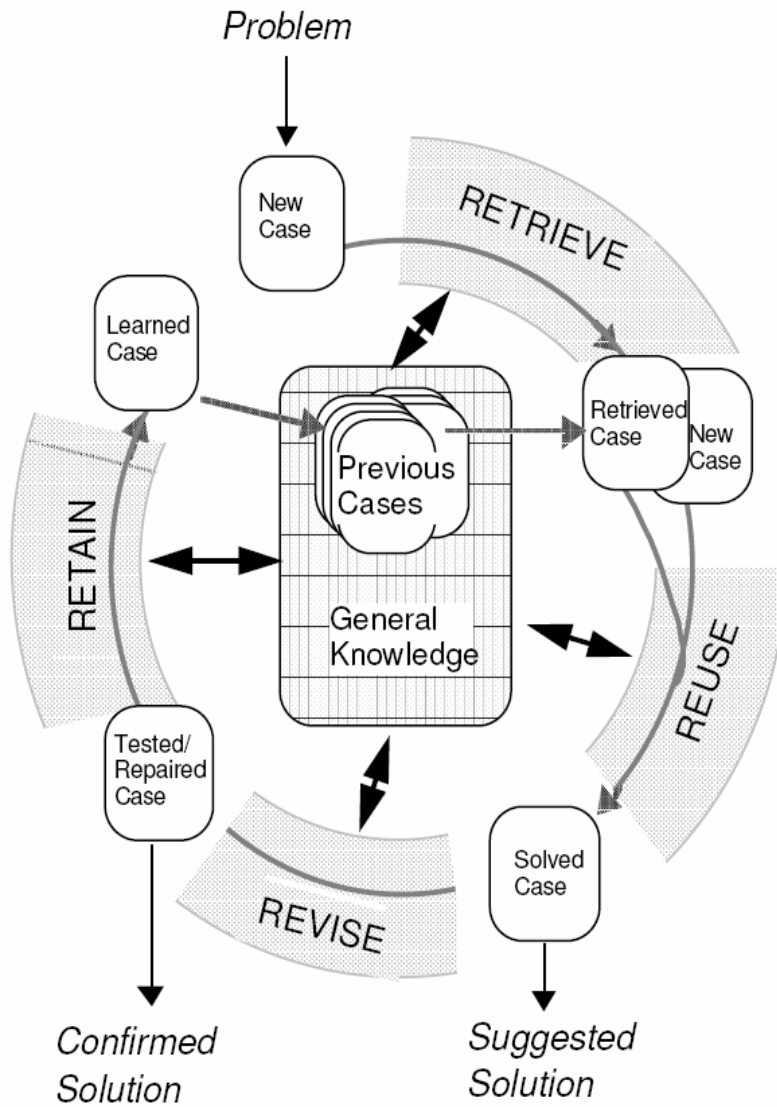
Fallformate:

Stark strukturiert :

z.B. Immobilien, Produkt-Kataloge, ... (Datenbanken)

Schwach bzw. heterogen strukturiert :

z.B. Fehlerprotokolle, Patientenakten, Baupläne, ...



R4-Modell von AAMONDT UND PLAZA

Zyklus:

1. **Aufbereitung des aktuellen Problems**

Beschreibungsform anpassen
Bestimmung von Merkmalen, Indizes

2. **Suche nach „relevanten/ähnlichen Fälle“**

mittels Indizierung, Ähnlichkeit, ...

3. **Auswahl der „brauchbaren Fälle“**

im Sinne „anwendbarer Erfahrungen“ (auch negativ)

4. **Konstruktion einer Lösung (Anpassung)**

„Argumentieren“ mit den vorliegenden Fällen,
Anpassung früherer Lösungen an das neue Problem

5. **Kritik der Lösung(en)**

Erneuter Vergleich mit der Falldatenbasis,
Simulation, ggf. weitere Anpassungsschritte

6. **Praktische Anwendung**

Analyse und Bewertung

7. **Aktualisierung der Falldatenbasis**

Einordnen des neuen Falls (Wissensakquisition)

Pflege der Falldatenbasis:

- Streichen („Vergessen“) irrelevanter Fälle
- Reduktion: Redundante Fälle streichen
- Korrektur der Auswahlkriterien (Ähnlichkeit)

2. Klassifikationsprobleme

- Menge O von Objekten o_1, o_2, \dots
- Menge \mathcal{K} von Klassen K_1, K_2, \dots (jeweils $K_i \subseteq O$), Zusatzforderung: $K_i \cap K_j = \emptyset$ für $i \neq j$

$K(o) :=$ (korrekte!) Klasse von o .

- Klassifikator:

$$\kappa : O \rightarrow \mathcal{K}$$

- korrekter Klassifikator:

$$\forall o \in O : \kappa(o) = K(o) \quad \text{d.h.: } o \in \kappa(o)$$

Merkmale (Attribute, Features, ...)

- Mehrere Merkmale m_1, m_2, \dots, m_n (Merkmalsmenge) jeweils über einer Wertemenge W_i
- Merkmale m_i ordnen den Objekten Werte aus einer Wertemenge W_i zu:

$$m_i : O \rightarrow W_i \quad (\text{evtl. partielle Funktion})$$

- Merkmalsraum: $M := W_1 \times \dots \times W_n$
- jedem Objekt $o \in O$ ist Merkmalsvektor zugeordnet (evtl. einige $m_i(o)$ nicht definiert):

$$m(o) := [m_1(o), \dots, m_n(o)]$$

Anforderung an M : $m(o') = m(o'') \Rightarrow o' = o''$

oder etwas schwächer: $m(o') = m(o'') \Rightarrow \kappa(o') = \kappa(o'')$

Klassifizierungsaufgabe neu formulieren:

gesucht wird eine Klassifikator $\kappa : M \rightarrow \mathcal{K}$ mit der Korrektheitsforderung $\forall o \in O : o \in \kappa(m(o))$

Beobachtungen:

1. Unterschiedliche Relevanz von Merkmalen

Extreme Varianten:

irrelevantes Merkmal: $m_i(o') = m_i(o'')$ für alle $o' \neq o''$

global unterscheidendes Merkmal $m_i(o') \neq m_i(o'')$ für alle $o' \neq o''$

i.a. nur Kombinationen von Merkmalen ausreichend für korrekte Klassifizierung

2. Redundanz: \Rightarrow Auswahl von Merkmalen

3. Clusterbildung:

Cluster = Objekte mit “**ähnlichen**” Merkmalen (z.B. “benachbart” bzgl. einer Distanz)

abhängig von Merkmalsauswahl/Ordnungen über W_{m_i}

Ziel: **Ähnlichkeit** (Distanz) entspricht Klassen: $m(o') \sim m(o'') \Rightarrow K(o') = K(o'')$

4. Evtl. bestehen Klassen aus mehreren Clustern.

\Rightarrow Weitere Anforderungen an Merkmalsauswahl.

Klassifizierungsverfahren

Komplexitätsprobleme:

a) bzgl. Konstruktion des Klassifizierungsverfahrens κ

b) bzgl. Ausführen einer Klassifikation $\kappa(o)$

Evtl. $\kappa(o)$ nur näherungsweise korrekt.

Im folgenden zunächst: Ähnlichkeit als inverse Distanz

Trennflächen : *Trennung der Klassen im Merkmalsraum M durch Trennflächen*

lineare Trennbarkeit: Klassen durch lineare Trennflächen separiert

Entscheiden, in welchem Teil des Raumes ein Merkmalsvektor $[m_1(o), \dots, m_n(o)]$ liegt.

Beispiel:

$$\text{Trennlinie } a \cdot x + b \cdot y + c = 0$$

$$\text{Klassifizierung für } (x_0, y_0) \text{ gemäß } a \cdot x_0 + b \cdot y_0 + c \geq 0 \text{ bzw. } a \cdot x_0 + b \cdot y_0 + c < 0$$

Support-Vektor-Maschinen

- Günstige Lage der Trennebene (gute Trennbarkeit)
- Transformation des Raumes für lineare Trennbarkeit

Nearest Neighbour Verfahren: Nähe zu bekannten Objekten

Gegeben eine Menge C von bekannten Objekten ("Fällen"):

$$C = \{ c_j = [m(c_j), \kappa(c_j)] \mid j = 1, \dots, r \}$$

Nearest Neighbour Verfahren:

$$\kappa(o) := \kappa(c_j) \text{ für } c_j := NN(o, C)$$

wobei

$$\begin{aligned} NN(o, C) &:= \text{ähnlichstes Objekt } c \in C \text{ für } o \\ &(\text{bzw. } := \text{Objekt } c \in C \text{ mit minimaler Distanz zu } o) \end{aligned}$$

(Problem: Eindeutigkeit von NN)

Korrektheit abhängig von

- Korrektheit der Fälle in C
- Ähnlichkeitsmaß (Distanzmaß)
- Vollständigkeit, Verteilung der Fälle in C

(vgl. Diskussion „Ähnliche Fälle haben ähnliche Lösungen“)

Voronoi-Diagramm: Trennflächen gemäß Nearest-Neighbour-Klassifikation

n Nearest Neighbour Verfahren:

Klassifizierung entsprechend der Mehrzahl der n nächstliegenden Objekte.

Mittel-/Schwerpunkte von Klassen (Clustern)

Klassifizierung entsprechend dem nächstliegenden
Mittel-/Schwerpunkt:

Mittelpunkt einer Klasse

$K = \{[m_1(o_1), \dots, m_n(o_1)], \dots, [m_1(o_{|K|}), \dots, m_n(o_{|K|})]\}$:

$$m_K := \frac{1}{|K|} \sum_{k=1, \dots, |K|} [m_1(o_k), \dots, m_n(o_k)]$$

Verfahren:

Nearest Neighbor Verfahren mit Fallbasis $C =$ Mittelpunkte

Analog für Schwerpunkte:

Schwerpunkt einer Klasse:

wie Mittelpunkt aber mit gewichteten Merkmalsvektoren

$$s_K := \frac{1}{|K|} \sum_{k=1, \dots, |K|} g_i \cdot [m_1(o_k), \dots, m_n(o_k)]$$

($g_i =$ Gewicht von m_i)

Entscheidungsbäume als Klassifikatoren

Zu klassifizieren: o

Eingabe: $m(o) = [m_1(o), \dots, m_n(o)]$

- Knoten mit Nachfolgern: Tests mit Verzweigung entsprechend Resultat.
z.B. Test: IF $m_1(o) > a$ THEN rechter Zweig ELSE linker Zweig
- Blattknoten: Ausgabe $\kappa(o)$

Test/Verzweigung als *Abschneiden* des Merkmalsraums:

Suche nur noch im ausgewählten Unterraum.

Bei einfachen Tests (z.B. $m_i > a$) : Teilräume begrenzt durch achsenparallele Ebenen.

Beobachtungen:

Wenig Tests bei “guter” Clusterung.

Wenig Tests bei guter Anordnung/Auswahl der Tests.

Klassifizierungsregeln

Erzeugbar z.B. aus Entscheidungsbäumen

(jeweils entlang der Pfade):

IF $m_i(o) > a_i$ **AND** $m_j(o) > a_j \dots$ **THEN** $\kappa(o) = K$

Neuronale Netze als Klassifikatoren

Statistische Verfahren

Lernverfahren zur Erzeugung von Klassifikatoren (Maschinelles Lernen)

Ausgangspunkt: Es sind nur einige Klassifizierungsbeispiele bekannt.

positive Beispiele: $[[m_1(o), \dots, m_n(o)], K]$ mit $o \in K$

evtl. auch

negative Beispiele: $[[m_1(o), \dots, m_n(o)], K]$ mit $o \notin K$

Ziel: Klassifikator κ ableiten, der (möglichst) korrekt ist.

- Entscheidungsbäume: *ID3 und Nachfolger, speziell C4.5*
- Entscheidungsregeln aus Entscheidungsbäumen
- Neuronale Netze z.B. mittels Backpropagation

Generalisierungen beim Lernen

Beispielmenge C gegeben. Konstruiert wird Klassifikator κ für *alle* Objekte.

Probleme:

- Wonach bestimmt sich Klassifizierung für $o \notin C$?
- muss Klassifikator für Beispiele aus C korrekt sein?

Induktiver Bias: Für Verallgemeinerung benutzte Annahme.

Beispiel: Nearest Neighbor mit Fallbasis C

$\forall c \in C : c \in \kappa(c).$

Für andere Objekte $o \notin C: \kappa(o) := \kappa(c)$ für $c := NN(o, C)$

\Rightarrow *Generalisierung* gemäß Nähe. (*induktiver bias*)

Beispiel: Lineare Trennflächen

\Rightarrow *Generalisierung* gemäß Trennflächen. (*induktiver bias*)

dabei evtl. Verzicht auf korrekte Klassifizierung aller Beispiele zwecks Vereinfachung der Teilräume (insbesondere könnten einige Beispiele fehlerhaft gewesen sein.)

3. Ähnlichkeit

„ähnliche Fälle haben ähnliche Lösungen“

An essay is like a fish.

TVERSKY

Any two things which are from one point of view similar may be dissimilar from another point of view.

POPPER

Eigentlich wichtig sind a-posteriori-Kriterien:

- Korrektheit der Klassifizierung
- Übertragbarkeit der Probleme/Lösungen
- Nützlichkeit der gefundenen Lösung
- Akzeptanz des Nutzers

Probleme:

- hoher Aufwand für Abschätzung
- Überprüfung erst nach Abschluss

Ersatz durch leichter faßbare a-priori-Kriterien:

- bzgl. Berechnung
- bzgl. Retrieval
- bzgl. Transparenz

⇒ Ähnlichkeit

Betrachten im folgenden zunächst **Merkmalsvektoren** als Objekte:

$$u \in U := \mathcal{R} \times \mathcal{R} \times \dots \times \mathcal{R}$$

Basis-Konzepte für Ähnlichkeit:

- Binäre Relation R_{SIM} über U
($R_{SIM}(u, v)$: “ u ist ähnlich zu v ”):

$$R_{SIM} \subseteq U \times U.$$

Beispiel:

Übereinstimmung bei mindestens 2 von 3 Merkmalen:

$$\begin{aligned} R_{SIM}([x_1, x_2, x_3], [y_1, y_2, y_3]) & \\ :\Leftrightarrow \exists i, j : 1 \leq i < j \leq 3 : x_i = y_i \wedge x_j = y_j. & \end{aligned} \tag{1}$$

- Ähnlichkeitsmaß SIM

($SIM(u, v)$): Grad der Ähnlichkeit zwischen u und v

$$SIM : U \times U \rightarrow S.$$

mit $S \subseteq \mathcal{R}$, z.B. $S = [0, 1]$.

Beispiele

– „*Simple matching coefficient*“:

$$SIM([x_1, x_2, x_3], [y_1, y_2, y_3]) := \frac{1}{3} \cdot \text{card}(\{i \mid x_i = y_i\}). \quad (2)$$

– Maß abhängig von Differenzen $x_i - y_i$ z.B.:

$$SIM([x_1, x_2, x_3], [y_1, y_2, y_3]) := \frac{1}{3} \cdot \sum_{i=1,2,3} \frac{1}{1 + |x_i - y_i|}. \quad (3)$$

- Nachbarschaft bzgl Distanz $DIST$
($DIST(u, v)$: Distanz zwischen u und v):

$$DIST : U \times U \rightarrow S.$$

Beispiel:

Manhattan-Distanz über $S = [0, \infty)$:

$$DIST([x_1, x_2, x_3], [y_1, y_2, y_3]) := \sum_{i=1,2,3} |x_i - y_i|. \quad (4)$$

Wertebereiche für $S \subseteq \mathcal{R}$ bei *DIST* bzw. *SIM*

$S = [0, 1]$ analog zu Stochastik, Fuzzy-Theorie etc.

- bei *SIM* : Maximaler Wert 1 : absolute Ähnlichkeit,
- bei *SIM* : Minimaler Wert 0 : absolute Unähnlichkeit,
- bei *DIST*: Minimaler Wert 0 : absolute Nähe,

$S = [0, \infty]$

- bei *DIST* üblich
- bei *SIM* :Problematisch für Selbst-Ähnlichkeit: Kein maximaler Wert für $SIM(x, x)$

S mit negativen Werten:

- Negative Ähnlichkeiten \Rightarrow : Ablehnung
- negative Distanzen?

Auswirkungen bzgl. Retrieval-Strategien (s.u.)

Undefinierte/unbekannte Werte

2 Interpretationen:

- unwichtig, egal
(z.B. fehlendes Attribut in einer Regel)
- unbekannt

Unterschiedliche Behandlung in Anfrage bzw. Fall bei FBS.

Möglichkeiten:

- Normierung über bekannte Werte, z.B.

$$\text{dist}(x, y) := \sqrt{\frac{1}{n} \sum_{i=1}^n |x_i - y_i|^2}$$

- Optimistisch:

Annahme: unbekannte Werte stimmen überein

$$\begin{aligned} & \text{SIM}([u_1, \dots, u_{i-1}, ?, u_{i+1}, \dots, u_n], [v_1, \dots, v_n]) \\ & := \text{Max}_{u_i \in \mathcal{R}} \text{SIM}([u_1, \dots, u_{i-1}, u_i, u_{i+1}, \dots, u_n], [v_1, \dots, v_n]) \end{aligned}$$

- Pessimistisch:

Annahme: unbekannte Werte stimmen nicht überein

$$\begin{aligned} & \text{SIM}([u_1, \dots, u_{i-1}, ?, u_{i+1}, \dots, u_n], [v_1, \dots, v_n]) \\ & := \text{Min}_{u_i \in \mathcal{R}} \text{SIM}([u_1, \dots, u_{i-1}, u_i, u_{i+1}, \dots, u_n], [v_1, \dots, v_n]) \end{aligned}$$

Beziehungen

- R_{SIM} betrachten als SIM mit $S = \{0, 1\}$.
- R_{SIM} definierbar aus SIM mittels *Nearest Neighbor* unter Bezug auf eine Fallmenge $C \subseteq U$:
 $R_{NN_C}(u, c) :\Leftrightarrow c = NN(u, C)$

d.h.

$$R_{NN_C}(u, c) :\Leftrightarrow \forall c' \in C : SIM(u, c) \geq SIM(u, c').$$

Analog für Distanzen:

$$NN_C(u, c) :\Leftrightarrow \forall c' \in C : DIST(u, c) \leq DIST(u, c').$$

Bemerkung: Definitionsbereich hierbei $U \times C$.

- R_{SIM} definierbar aus SIM mittels „Mindest-Ähnlichkeit“ b :

$$R_{SIM_b}(u, v) := SIM(u, v) > b.$$

(Analog für Distanz mit $DIST(u, v) < b$.)

Vergleichsrelationen

Definitionen:

- *y ist ähnlicher zu x als v zu u :*

4-stellige Relation $V4_{SIM}(x, y, u, v)$ mit

1. $\forall x, u, v : V4_{SIM}(x, x, u, v)$
(Reflexivität)

2. $\forall x, y, u, v : V4_{SIM}(x, y, u, v) \Leftrightarrow V4_{SIM}(y, x, u, v)$
 $\Leftrightarrow V4_{SIM}(x, y, v, u)$

(Symmetrie, evtl. verzichtbar, s.u.)

- *y ist ähnlicher zu x als z :*

3-stellige Relation $V3_{SIM}(x, y, z)$ definierbar durch

$$V3_{SIM}(x, y, z) := V4_{SIM}(x, y, x, z)$$

- **Präferenzrelation bzgl. fixiertem x :**

2-stellige Relation $PREF_x(y, z)$ definiert durch

$$PREF_x(y, z) := V3_{SIM}(x, y, z)$$

$PREF_x(y, z)$ ist Halbordnung,

Maximale Elemente = Nearest Neighbor(s).

Im FBS: x als Anfrage.

Kompatibilität

Definition

Gegeben SIM bzw. $DIST$

$$V4_{SIM}(x, y, u, v) :\Leftrightarrow SIM(x, y) \geq SIM(u, v),$$

$$V4_{DIST}(x, y, u, v) :\Leftrightarrow DIST(x, y) \leq DIST(u, v).$$

Zwei (Ähnlichkeits- oder Distanz-)Maße m_1 und m_2 sind **relational kompatibel** gdw.

$$\forall x, y, u, v \in U : V4_{m_1}(x, y, u, v) \Leftrightarrow V4_{m_2}(x, y, u, v).$$

(Evtl. nur auf Teilmengen von $U \times U \times U \times U$.)

Kompatible Transformation zwischen Maßen m_1 und m_2 durch Funktion f mit

1. Respektierung der Wertebereiche S_i der Maße m_i ,
2. Respektierung der “Reflexivitätsbedingungen” (s.u.), z.B. $SIM(x, x) = 1$, $DIST(x, x) = 0$
3. Respektierung der Kompatibilitätsbedingung, z.B. durch eineindeutige Funktion

Beispiele:

Funktion f für Umwandlung

$$DIST : U \times U \rightarrow [0, \infty] \quad \Rightarrow \quad SIM : U \times U \rightarrow [0, 1]$$

f monoton fallend, $f(0) = 1$, $\lim_{x \rightarrow \infty} f(x) = 0$.

z.B.:

$$f(x) = \frac{1}{1+x}$$

Funktion f für Umwandlung

$$SIM : U \times U \rightarrow [0, 1] \quad \Rightarrow \quad DIST : U \times U \rightarrow [0, \infty]$$

f monoton fallend, $f(1) = 0$, $\lim_{x \rightarrow 0} f(x) = \infty$.

z.B.:

$$f(x) := \frac{1-x}{x}$$

Mögliche Annahmen (Axiome)

(z.B. für $S = [0, 1]$ bzw. $S = [0, \infty]$)

Reflexivität

$$SIM(x, x) = 1 \quad \text{und für Distanzen:} \quad DIST(x, x) = 0.$$

Symmetrie

$$SIM(x, y) = SIM(y, x) \quad \text{und} \quad DIST(x, y) = DIST(y, x).$$

Dreiecksungleichung

$$DIST(x, z) \leq DIST(x, y) + DIST(y, z).$$

(Bzgl. Ähnlichkeit: s.u.)

Einzig ständige Voraussetzung im folgenden:

Reflexivität in der Form $SIM(x, x) = 1$ bzw. $DIST(x, x) = 0$.

Reflexivität

$SIM(x, x) = 1$ bzw. $DIST(x, x) = 0$. sichert: $c = NN(c, C)$ für $c \in C$

Evtl. schärfer: „*starke Reflexivität*“

$$SIM(x, y) = 1 \leftrightarrow x = y \quad \text{und} \quad DIST(x, y) = 0 \leftrightarrow x = y.$$

(z.B. bei Metriken)

Symmetrie

Im FBS: Vergleich von Anfragen $q \in U$ mit Fällen $c \in C$ (bzw. mit „Problembeschreibungen“).
Bsp.: Nearest neighbor.

⇒ unsymmetrische Definitionsbereiche: *SIM* bzw. *DIST* definiert auf $U \times C$

Unsymmetrie in Alltagssprache („gerichtete Vergleiche“):

- Tochter ähnlich zur Mutter,
- Pinguin ähnlich zu Vogel,
- Anfrage ähnlich zu Dokument

Distanzen (speziell Metriken): symmetrisch.

Transitivität, Dreiecksungleichung

Ähnlichkeits-Relationen R_{SIM} i.a. nicht transitiv.

In Beispiel (1):

$R_{SIM}([1, 1, 1], [1, 1, 0])$ und $R_{SIM}([1, 1, 0], [1, 0, 0])$, aber nicht $R_{SIM}([1, 1, 1], [1, 0, 0])$.

Dreiecksungleichung für Ähnlichkeitsmaße?

Für Distanzen gilt: $DIST(x, z) \leq DIST(x, y) + DIST(y, z)$.

Was passiert bei Übergang mittels kompatibler Transformation f :

- allgemein:

$$f(SIM(u, w)) \leq f(SIM(u, v)) + f(SIM(v, w)).$$

schwer interpretierbar:

- z.B. für $f(x) = 1 - x$:

$$SIM(u, v) + SIM(v, w) \leq 1 + SIM(u, w).$$

Anderer Zugang:

Invertierung der Dreiecksungleichung für Distanzen:

$$SIM(u, w) \geq SIM(u, v) + SIM(v, w).$$

Zusammen mit Reflexivität und Symmetrie:

$$1 = SIM(u, u) \geq SIM(u, v) + SIM(v, u) = 2 \cdot SIM(u, v),$$

d.h. $SIM(u, v) \leq 0.5$ für beliebige u, v .

Analog:

$$SIM(u, w) \leq SIM(u, v) + SIM(v, w)$$

führt zu $SIM(u, v) \geq 0.5$ für beliebige u, v .

Spezielles Beispiel:

$$SIM([x_1, x_2], [y_1, y_2]) := \text{Min}(\{ 1, \text{card}(\{ i \mid x_i = y_i \}) \}). \quad (5)$$

mit

$$SIM([0, 0], [0, 1]) = SIM([0, 1], [1, 1]) = SIM([0, 0], [0, 0]) = 1$$

$$SIM([0, 0], [1, 1]) = SIM([1, 1], [0, 0]) = 0$$

daraus folgt:

$$SIM([0, 0], [0, 1]) + SIM([0, 1], [1, 1]) > SIM([0, 0], [1, 1])$$

$$SIM([0, 0], [1, 1]) + SIM([1, 1], [0, 0]) < SIM([0, 0], [0, 0]).$$

Kompatible Transformation f mit $f(0) = 1$ und $f(1) = 0$

für Übergang von SIM zu $DIST$ ergibt:

$$DIST([0, 0], [0, 1]) + DIST([0, 1], [1, 1]) < DIST([0, 0], [1, 1]).$$

⇒ Es gibt aus Ähnlichkeitsmaßen abgeleitete intuitive Distanzmaße,
die die Dreiecksungleichung nicht erfüllen (insbesondere keine Metriken sind).

Bemerkung:

Es gibt stets relational kompatible Metrik für symmetrisches Ähnlichkeitsmaß $SIM : U \times U \rightarrow [0, 1]$:

$$DIST(u, v) := \begin{cases} 0 & , \text{ falls } u = v \\ \frac{1}{2} \cdot (2 - SIM(u, v)) & , \text{ sonst.} \end{cases} \quad (6)$$

(Dreiecksungleichung gilt wegen $\frac{1}{2} \leq DIST(u, v) \leq 1$.)

Kompositorische Maße

Das Lokal-Global-Prinzip

Gegeben: Attribute A_1, \dots, A_n für die Komponenten.

Definition

Lokal-Global-Prinzip für Ähnlichkeiten (bzw. Distanzen):

- *Lokales Ähnlichkeitsmaß* für Attribute A_i : $sim_i : \mathcal{R} \times \mathcal{R} \rightarrow \mathcal{R}$
- *Kompositionsfunktion* $COMP : \mathcal{R} \times \dots \times \mathcal{R} \rightarrow \mathcal{R}$

Ein („globales“) Ähnlichkeitsmaß $SIM : \mathcal{R} \times \dots \times \mathcal{R} \rightarrow \mathcal{R}$ heißt *kompositorisch*, wenn es mit lokalen Ähnlichkeitsmaßen und einer Kompositionsfunktion definierbar ist:

$$SIM([q_1, \dots, q_n], [u_1, \dots, u_n]) = COMP(sim_1(q_1, u_1), \dots, sim_n(q_n, u_n)).$$

Analog für Distanzen mit lokalen Distanzen $dist_i : \mathcal{R} \times \mathcal{R} \rightarrow \mathcal{R}$:

$$DIST([q_1, \dots, q_n], [u_1, \dots, u_n]) = COMP(dist_1(q_1, u_1), \dots, dist_n(q_n, u_n)).$$

Beispiele:

- Gewichtete Hamming-Maße:

$$SIM([q_1, \dots, q_n], [u_1, \dots, u_n]) = \sum_{i=1, \dots, n} w_i \cdot sim_i(q_i, u_i). \quad (7)$$

- Euklidische Distanz:

$$DIST([q_1, \dots, q_n], [u_1, \dots, u_n]) = \sqrt{\sum_{i=1, \dots, n} dist_i(q_i, u_i)}. \quad (8)$$

mit $dist_i(q_i, u_i) = |q_i - u_i|^2$.

- Fuzzy-Operatoren (t-norm, t-co-norm) als Kompositionsfunktionen mit linguistischen Termen als lokale Ähnlichkeitsmaße (s.u.).

Das Globale Monotonie-Axiom

$$\boxed{SIM(u, v) > SIM(u, w) \rightarrow \exists i \in \{1, \dots, n\} : sim_i(u_i, v_i) > sim_i(u_i, w_i).}$$

Gilt aber nicht immer. Gegenbeispiel („XOR-problem“):

$$U := \{[0, 0], [0, 1], [1, 0], [1, 1]\}$$

$SIM([u_1, u_2], [v_1, v_2]) = 1$ gdw. $XOR(u_1, u_2) = XOR(v_1, v_2)$, d.h.:

$$\begin{aligned} SIM([0, 0], [1, 1]) &= SIM([0, 1], [1, 0]) = 1 \\ SIM([0, 0], [0, 1]) &= SIM([0, 0], [1, 0]) \\ &= SIM([1, 1], [1, 0]) = SIM([1, 1], [0, 1]) = 0. \end{aligned}$$

folglich $SIM([0, 0], [1, 1]) > SIM([0, 0], [0, 1])$.

aber: $sim_1(0, 1) \leq sim_1(0, 0) = 1$ (Reflexivität) und $sim_2(0, 1) = sim_2(0, 1)$.

Lokales Monotonie-Axiom:

$$|u_i - v_i| < |u'_i - v'_i| \Leftrightarrow \text{DIST}(u_i, v_i) < \text{DIST}(u'_i, v'_i)$$

$$|u_i - v_i| < |u'_i - v'_i| \Leftrightarrow \text{SIM}(u_i, v_i) > \text{SIM}(u'_i, v'_i)$$

Gilt nicht immer, Gegenbeispiel:

$$\text{sim}(x, y) := \begin{cases} 1 & , \text{ if } x = y \text{ oder } x, y \in \mathcal{N} \\ 0 & , \text{ otherwise.} \end{cases} \quad (9)$$

Transformationen für Kompositorische Maße

Relational kompatible Transformationen auf der

- Lokalen Ebene: $sim_i, dist_i$
- Globalen Ebene: $SIM, DIST$

Beispiel für kompatible Transformationsfunktion:

$$\frac{1}{1+x}$$

Vgl. Beispiel (3):

Lokale Distanzen: $dist_i(x_i, y_i) = |x_i - y_i|$

Transformierte lokale Ähnlichkeitsmaße: $sim_i(x_i, y_i) = \frac{1}{1+|x_i-y_i|}$

⇒ Globales Ähnlichkeitsmaß SIM :

$$SIM([x_1, x_2, x_3], [y_1, y_2, y_3]) := \frac{1}{3} \cdot \sum_{i=1,2,3} \frac{1}{1+|x_i - y_i|}.$$

Dagegen bei Transformation auf der globalen Ebene:

$$SIM'([x_1, x_2, x_3], [y_1, y_2, y_3]) := \frac{1}{1 + DIST([x_1, x_2, x_3], [y_1, y_2, y_3])} \quad (10)$$

d.h.:

$$SIM'([x_1, x_2, x_3], [y_1, y_2, y_3]) = \frac{1}{1 + \sum_{i=1,2,3} |x_i - y_i|}. \quad (11)$$

Komposition und Transformation nicht vertauschbar.

Lokale Maße, Merkmalstypen, Skalen

Merkmale (jetzt auch nicht-numerische Wertebereiche):

Qualitative Merkmale :

Beispiele:

- rot, grün, blau, ...
- ledig, verheiratet, geschieden, ...
- kalt, lau, warm, ...

Evtl. (halb-)geordnet, evtl. mit Ähnlichkeit.

Quantitative Merkmale :

Numerisch.

Geordnet.

Skalen:

Nominalskala : ungeordnet

Spezialfall *binäre Skala*: 2 Werte, z.B. „ja“, „nein“.

Ordinalskala/Rangskala : geordnet.

Metrische Skala : metrisch geordnet.

(Metrik: nicht-negativ, starke Reflexivität, Symmetrie, Dreiecksungleichung)

Ähnlichkeit z.B.

- definierbar durch Vergleichsrelation $V3$
bei gegebener (Halb-)Ordnung ORD :

$$y \text{ ist ähnlicher zu } x \text{ als } z \quad V3_{SIM}(x, y, z) \\ := (ORD(x, y) \wedge ORD(y, z)) \vee (ORD(z, y) \wedge ORD(y, x))$$

- definierbar als inverse Distanzen
- gegeben durch Synonyme, ähnliche Begriffe, ...
- gegeben durch unscharfe Begriffe (linguistische Terme)

Ähnlichkeit zwischen konkreten Werten und linguistischen Termen

- Unscharfe Begriffe:

billig

ungefähr 1000 DM

Sommer



- Scharfe Begriffe:

Ferienzeit

- Ähnliche Begriffe:

Sommer – Ferienzeit

6000 DM – 5499 DM



Wort(-gruppen)-Ähnlichkeit in Texten

- Identische Bedeutung
 - Beugung, Zahl (**Printers**)
 - Sprache (**Drucker**)
 - Synonyme (**LaserJet**)

- Ähnliche Bedeutung
 - ähnlich (**Plotter**)
 - Wortgruppe (**Output Device**)
 - Gemeinsames Auftreten (**PostScript**)


⇒ Kontext-abhängig

Lokale Transformation: Ähnlichkeit \leftrightarrow Distanz


Kompatibilität: $SIM(x, y) \geq SIM(u, v) \Leftrightarrow DIST(x, y) \leq DIST(u, v)$

Transformationsfunktion z.B.

$$\frac{1}{1+x}$$



$$dist_i(x_i, y_i) = |x_i - y_i|$$



$$sim_i(x_i, y_i) = \frac{1}{1+|x_i - y_i|}$$

Kombination lokaler Ähnlichkeiten

Lokal-Global-Prinzip für Ähnlichkeiten (bzw. Distanzen)
bei beliebigen Wertebereichen W_i der Attribute A_i .

- *Lokales Ähnlichkeitsmaß* für Attribute A_i : $sim_i : W_i \times W_i \rightarrow \mathcal{R}$
- *Lokale Distanz* für Attribute A_i : $dist_i : W_i \times W_i \rightarrow \mathcal{R}$
- *Kompositionsfunktion* $COMP : \mathcal{R} \times \dots \times \mathcal{R} \rightarrow \mathcal{R}$

Kompositorisches Ähnlichkeitsmaß:

$$SIM([q_1, \dots, q_n], [u_1, \dots, u_n]) = COMP(sim_1(q_1, u_1), \dots, sim_n(q_n, u_n)).$$

Kompositorische Distanz:

$$DIST([q_1, \dots, q_n], [u_1, \dots, u_n]) = COMP(dist_1(q_1, u_1), \dots, dist_n(q_n, u_n)).$$

Beispiele für **reelle Merkmalswerte**:

Euklidischer Abstand:

$$DIST(x, y) := \sqrt{\sum_{i=1}^n |x_i - y_i|^2}$$

Minkowski-Metriken

$$DIST(x, y)^{(r)} := \left(\sum_{i=1}^n |x_i - y_i|^r \right)^{\frac{1}{r}}$$

für $r = 2$: euklidische Metrik

für $r = 1$: Manhattan-Metrik

für $r \rightarrow \infty$: Maximum-Norm

$$DIST(x, y)^{(\infty)} = \text{Max}\{|x_i - y_i| / i = 1, \dots, n\}$$

Fuzzy-Theorie:

t-norm, z.B. Minimum (verallgemeinerte “Konjunktion”)

t-co-norm, z.B. Maximum (verallgemeinerte “Alternative”)

Probleme:

- Skalierung (Dehnung/Stauchung)

⇒ Normierung aller Merkmale z.B. auf Skala $[0, 1]$ durch merkmalsabhängigen Faktor σ_i , z.B.:

$$DIST(x, y) := \sqrt{\sum_{i=1}^n (\sigma_i \cdot |x_i - y_i|)^2}$$

- Wichtung von Merkmalen durch merkmalsabhängiges Gewicht γ_i , z.B.:

$$DIST(x, y) := \sqrt{\sum_{i=1}^n \gamma_i \cdot |x_i - y_i|^2}$$

Skalierung durch Wichtung i.a. nicht ersetzbar.

Ausgleich bei fehlenden Werten (variablen n):

$$dist(x, y) := \sqrt{\frac{1}{n} \sum_{i=1}^n |x_i - y_i|^2}$$

(andere Varianten: optimistisch/pessimistisch)

Beispiele für **Binäre Merkmalswerte**: $x = [x_1, \dots, x_n]$, $y = [y_1, \dots, y_n]$ jeweils aus $\{0, 1\}^n$

Kontingenztafel:

$$\begin{aligned}a &= \sum_{i=1}^n x_i \cdot y_i \\b &= \sum_{i=1}^n x_i \cdot (1 - y_i) \\c &= \sum_{i=1}^n (1 - x_i) \cdot y_i \\d &= \sum_{i=1}^n (1 - x_i) \cdot (1 - y_i)\end{aligned}$$

Hamming-Abstand: $DIST(x, y) = b + c$

Simple-Matching-Coefficient: $SIM(x, y) = \frac{a+d}{a+b+c+d}$

Gewichtete Strategien („optimistisch“: $g > 0,5$ bzw. „pessimistisch“: $g < 0,5$):

$$SIM(x, y) = \frac{g \cdot (a + d)}{g \cdot (a + d) + (1 - g) \cdot (b + c)}$$

Reduktion von nominalen Skalen auf binäre Skalen:

Bsp.: Merkmal $Farbe \in \{rot, grün, blau\}$

übersetzen in binären Merkmalsvektor $[w_{rot}, w_{grün}, w_{blau}]$ mit $w_{rot} = 1 \Leftrightarrow Farbe = rot$ usw.

Dabei ein bzgl. 0/1 asymmetrisches Maß benutzen, z.B.

$$SIM(x, y) = \frac{a}{a + b + c}$$

Contrast Rule (TVERSKY):


Objekte (S = „Situation“, P = „Prototyp“) beschrieben als Menge ihrer Eigenschaften.
Jede Eigenschaft wird mit einem Gewicht g_i bewertet.

$$SIM(S, P) = \alpha \cdot \sum_{i \in S \cap P} g_i - \beta \cdot \sum_{i \in P - S} g_i - \gamma \cdot \sum_{i \in S - P} g_i$$

(α, β, γ als weitere Gewichte)


Unterschiedliche Charakteristiken (=Linien gleicher Ähnlichkeit/Distanz)

Lokale Distanzen




$$f(x) = |x|$$


Globale Distanzen



$$|q_1 - c_1| + |q_2 - c_2| = d$$




$$f(x) = x^2$$




$$(q_1 - c_1)^2 + (q_2 - c_2)^2 = d$$

Lokale Ähnlichkeiten




$$f(x) = 1/(1 + |x|)$$


Globale Ähnlichkeiten




$$1/(1 + |q_1 - c_1|) + 1/(1 + |q_2 - c_2|) = a$$




$$f(x) = \text{Gauss}(x, 0, 0.5)$$



$$\text{Gauss}(q_1 - c_1, 0, 0.5) + \text{Gauss}(q_2 - c_2, 0, 0.5) = a$$



$$f(x) = 1 - |x|$$



$$(1 - |q_1 - c_1|) + (1 - |q_2 - c_2|) = a$$

Intuitive Bedeutung kompositorischer Maße

Speziell *Gewichtete Summen*:

Akkumulation lokaler Werte zu globalem Wert mit (fixierten) Gewichten der Attribute

- **Distanz:**
akkumuliert *Argumente für Ausschluß*

Akkumulation für Zurückweisung

- **Ähnlichkeit:**
akkumuliert *Argumente für Annahme*

Akkumulation für Akzeptanz

Akkumulation für Zurückweisung :

Einzelne große Distanz \rightarrow Zurückweisug.

Nächster Nachbar: *Alle* lokalen Werte sind nah.

Methode: Entscheidungsbaum

(“top down pruning”)

Akkumulation für Akzeptanz :

Hinreichend viele lokale Werte ähnlich \rightarrow Akzeptanz.

\rightarrow Kompromisse (!)

Methode: Case Retrieval Netze

(“bottom up collecting”)

Unterschiede Ähnlichkeit/Distanz:

- Ähnlichkeit akkumuliert Argumente für Akzeptanz.
- Distanz akkumuliert Argumente für Zurückweisung.

Grundproblem bezüglich Ähnlichkeit/Distanz:

1. Ähnlichkeit/Distanz impliziert Nützlichkeit.
2. Ähnlichkeit/Distanz basiert auf a-priori-Fakten.
3. Ähnlichkeit/Distanz als quantitatives Maß.

Dafür

- Auswahl geeigneter Merkmale.
- Auswahl geeigneter (intuitiver) Maße für Ähnlichkeit/Distanz:
 1. Lokale Ähnlichkeiten/Distanzen
 2. Kompositionsfunktion
 3. Akkumulationsprinzip (Akzeptanz vs. Zurückweisung)

Globale/lokale Monotonie unterstützen Intuitivität.