

Aufgabenstellung

- Muster- / Strukturerkennung
- Vorhersage / Abschätzung der Entwicklung des Systems / der Umgebung in naher/ferner Zukunft

Was ist notwendig?

- Ein Agent (z.B. Physiker)
- Möglichkeit Daten aufzunehmen (z.B. Messgeräte)
- Eine Datenbank, in der die Muster abgespeichert sind, die wir erkennen können (z.B. Erfahrung)

Übersetzung


- Struktur= Funktion
- Daten=Graph dieser Funktion
- Musterbibliothek=Schar von Funktionen
- Struktur erkennen=passende Funktion aus dieser Schar auswählen

Bemerkung: wir beschränken uns auf Abb
(\mathbb{R}, \mathbb{R})


Kontrolle der Auswahl

- Normen bzw. Metriken
- Annahme : f, g aus L^2
 - > $d := \int (f-g)^2 dt$ – eine MetrikDaten sind aber nicht kontinuierlich
 - > d muss abgeschätzt werden
$$d_a := \sum (f(t_i) - g(t_i))^2$$


Problem:: Overfitting



Weitere Entwicklung



Weitere Entwicklung(Ausschnitt)



Zusammenfassung

- Zu einfach – schlecht
- zu kompliziert -schlecht

-> goldene Mitte suchen

notwendig

Fazit: ein neues Konzept

Stochastische Komplexität

1984 von Rissanen vorgeschlagen, und im Zusammenhang mit dem MDL (Minimum Description Length) – Prinzip entwickelt

Idee

- Kompression = Lernen = Vorhersagen
- höhere Kompressionsrate \rightarrow mehr gelernt \rightarrow genauere Vorhersagen

- Beispiel:

x :	1	2	3	4	5
y:	1	4	9	16	?

Kompression: x-Werte und $y=x^2$

Was ist jetzt unser Kriterium?

Das MDL – Prinzip!

Gegeben:

verschiedene Modelle mit verschiedenen
Kompressionsraten.

Man wähle das Modell mit der höchsten
Kompressionsrate.

Wie komprimiert man Daten? (I)

1. Kodierung

Prefix-Kodierung

Ergebnis: Folge aus 1s und 0s

2. Man wählt den bestmöglichen Kode

z.B. $A = \{1, 2, 3\}$

klug: $1 = "0"$, $2 = "10"$, $3 = "11"$

weniger klug: $1 = "001"$ $2 = "010"$ $3 = "100"$

Wie komprimiert man Daten? (II)

Große Zahlen speichern -> mehr Platz notwendig

Beispiel:

$A = \{0, 1\}$ pro Zahl 1 bit notwendig

$B = \{0 \dots 1023\}$ pro Zahl 10 bit notwendig

Allgemein:

$A = \{a, a+1, a+2, \dots, a+n-1\}$

die Länge des Codes pro Element im
Wesentlichen von n abhängig

Wie komprimiert man Daten? (III)

Erstrebenswert: n möglichst klein zu halten.

Zu jedem n eigener Kode

Problem:: Mitteilen welcher Kode benutzt wird
= Die Nummer des Kodes mitteilen.

Anforderung:

Mit dem wachsenden n darf die Länge dieser Mitteilung nicht explodieren.

Beispiel(I)

Voraussetzungen:

Der Agent kennt nur Polynome mit $\text{grad}(p) \leq n$.

Die Daten (D) besitzen endliche Genauigkeit
(y hat abzählbar viele Zustände)

Aufgabe:

D zu komprimieren bzw. eine Struktur in D
zu finden

Beispiel(II)

Was hat unser Agent zu tun?

X-Werte kodieren

das gewählte Polynom p kodieren. (Länge L_p)

die Werte von $y-p(x)$ kodieren. (Länge $L_{y|p}$)

versuchen $L_p + L_{y|p}$ zu minimieren

Beispiel(III)

Ist das Problem des Overfittings gelöst?

Im Prinzip: Ja!

Für das Polynom p mit $\text{grad}(p)=n-1$:

$$L_{y|p} = 0$$

$$L_p = (n-1) * C'$$

$$\rightarrow L = L_p + L_{y|p} = (n-1) * C$$

y -Werte ($p=0$):

$$L = L_{y|0} = n * C'$$

Definition

$SK(D | M)$:= Stochastische Komplexität des Datensatzes D bezüglich des Modells M

$$SK(D | M) = L_{D|M}$$

Konkretes triviales Beispiel

Voraussetzungen:

Bekannt: Polynome

Daten:

x :	1	2	3	4	5
y:	1	4	9	16	25

Lösung:

Nach MDL-Prinzip wird $y=x^2$ gewählt.

(weder $y=ax$ noch $y=p$ mit $\text{grad}(p) \geq 5$)

Philosophie des MDL-Prinzips

Annahmen:

- (i) Der Agent kennt die Funktionenschar H
- (ii) $Y=f(X)+S$; wobei f aus H und S – eine (probalistische) Störung.

Dann kann man mit Hilfe des MDL -Prinzips f finden.

Wichtig: ob (ii) erfüllt ist total irrelevant

Zweites Beispiel

Sei S – Störung nach Gaußverteilung mit konstanter Varianz.

Rechnung:

MDL besagt:

$\sum (f(x_i) - y(x_i))^2$ ist zu minimieren.

Also begründet das MDL Prinzip die Regression, die in der Praxis sehr gute Ergebnisse bringt

Probleme

Man kann nur die bekannten Muster unterscheiden

z.B. Die Zahl Pi wird nicht erkannt.

-> Innovationen notwendig

Numerische Verfahren nicht entwickelt/ (Zeit)

Aufwand in die Betrachtung nicht einbezogen