

# Kerne und Kostenfunktionale

Franziska Häußler

Universität Ulm  
Fakultät für Mathematik und Wirtschaftswissenschaften

22. Mai 2007

# Inhaltsverzeichnis

## 1. Kerne

### 1.1 Motivation

### 1.2 Kerne als Ähnlichkeitsmaße

### 1.3 Kerne als Nicht-Ähnlichkeitsmaße

# Inhaltsverzeichnis

## 1. Kerne

1.1 Motivation

1.2 Kerne als Ähnlichkeitsmaße

1.3 Kerne als Nicht-Ähnlichkeitsmaße

## 2. Kostenfunktionale

2.1 Grundlagen

2.2 Testfehler und erwartetes Risiko

2.3 Statistisches Konzept des Kostenfunktionalen

2.4 Bewertung von Schätzern

# Inhaltsverzeichnis

## 1. Kerne

### 1.1 Motivation

### 1.2 Kerne als Ähnlichkeitsmaße

### 1.3 Kerne als Nicht-Ähnlichkeitsmaße

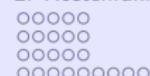
## 2. Kostenfunktionale

### 2.1 Grundlagen

### 2.2 Testfehler und erwartetes Risiko

### 2.3 Statistisches Konzept des Kostenfunktionalen

### 2.4 Bewertung von Schätzern



# Einleitung

- ▶ Grundproblem der statistischen Lerntheorie: aus Daten lernen
- ▶ Linearer Ansatz
  - ▶ Vorteil: einfache Algorithmen
  - ▶ Nachteil: geringe Flexibilität
- ▶ Nicht-linearer Ansatz
  - ▶ Vorteil: bessere Anpassung
  - ▶ Nachteil: zu hohe algorithmische Komplexität
- ▶ Lösung dieses Dilemmas: **Kerne**



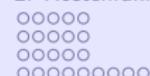
## Warum Kerne?

1. Verbindung der Vorteile:  
Beschreibung von nicht-linearen als lineare Abbildungen in  
sog. Merkmalsräumen
2. Verwendung von einfachen, exakt lösbaren  
Optimierungsverfahren
3. Auch Verbesserung gegenüber Neuronalen Netzen



# Was sind Kerne?

1. **Ähnlichkeitsmaße**
2. **Nicht-Ähnlichkeitsmaße**



# Konventionen

- ▶ Auf den folgenden Folien gilt:
- ▶ Merkmalabbildung:  $\Phi : \mathcal{X} \rightarrow \mathcal{H}$ ,
- ▶ Eingabemenge:  $\mathcal{X} \subset \mathbb{R}^N$ , nicht leer
- ▶ Merkmalraum:  $\mathcal{H}$ , i.A. mit  $\dim(\mathcal{X}) \ll \dim(\mathcal{H})$
- ▶  $\mathbb{K} = \mathbb{R}$  oder  $\mathbb{C}$

# Inhaltsverzeichnis

## 1. Kerne

### 1.1 Motivation

### 1.2 Kerne als Ähnlichkeitsmaße

### 1.3 Kerne als Nicht-Ähnlichkeitsmaße

## 2. Kostenfunktionale

### 2.1 Grundlagen

### 2.2 Testfehler und erwartetes Risiko

### 2.3 Statistisches Konzept des Kostenfunktionalen

### 2.4 Bewertung von Schätzern

## Kern als Ähnlichkeitsmaß

- ▶ Definition: Abbildung

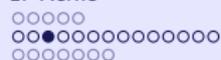
$$k : \mathcal{X} \times \mathcal{X} \rightarrow \mathbb{K}$$

- ▶ mit **Symmetrie-Eigenschaft**

$$\forall x, x' \in \mathcal{X} : k(x, x') = \overline{k(x', x)}$$

- ▶ und **positiver Definitheit**

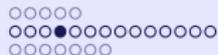
$$\sum_{i,j=1}^m (c_i \bar{c}_j k(x_i, x_j)) \geq 0, \quad \forall c_i \in \mathbb{K}$$



## Rechenbeispiel

- ▶ Geg.:  $\Phi : \mathbb{R}^2 \rightarrow \mathbb{R}^3 = \mathcal{H}$ ,  $(x_1, x_2) \mapsto (x_1^2, \sqrt{2}x_1x_2, x_2^2)$
- ▶ Wähle  $k$  als Skalarprodukt von  $\Phi$  im Merkmalraum  $\mathcal{H}$
- ▶ Berechnung des Kerns:

$$\begin{aligned}
 k(x, x') &= \langle \Phi(x), \Phi(x') \rangle \\
 &= (x_1^2, \sqrt{2}x_1x_2, x_2^2)^T (x_1'^2, \sqrt{2}x_1'x_2', x_2'^2) \\
 &= x_1^2x_1'^2 + 2x_1x_2x_1'x_2' + x_2^2x_2'^2 \\
 &= (x_1x_1' + x_2x_2')^2 \\
 &= \langle x, x' \rangle^2
 \end{aligned}$$



## Interpretation

- ▶ Kerne als Ähnlichkeitsmaße spiegeln Ähnlichkeit zweier Objekte wider
- ▶ **Je größer** der Wert des **Ähnlichkeitsmaßes**, **desto ähnlicher** sind die **Objekte** (folgt aus der Cauchy-Schwarzschen-Ungleichung für Kerne)
- ▶ Eigenschaft: Positive Definitheit, Symmetrie



## Konstruktion eines Merkmalraumes (1)

- ▶ Wähle z.B. Hilbertraum  $L_2(\mathcal{X})$
- ▶ Problem: enthält viele nicht-glatte Funktionen
- ▶ Lösung: Hilbertraum auf kleinere Menge von Funktionen einschränken  
 $\hat{=}$  **Reproducing Kernel Hilbert Space**



## Reproducing Kernel Hilbert Space (RKHS)

- ▶ Definition: Sei  $\mathcal{H}$  Hilbertraum mit Funktionen  $f : \mathcal{X} \rightarrow \mathbb{R}$ , Skalarprodukt  $\langle \cdot, \cdot \rangle$  (und Norm  $\|f\| := \sqrt{\langle f, f \rangle}$ ), falls  $\exists k : \mathcal{X} \times \mathcal{X} \rightarrow \mathbb{R}$  mit folgenden Eigenschaften:

### 1. Reproduzierungseigenschaft:

$$\langle k(\cdot, x), f(\cdot) \rangle = f(x) \text{ und } \langle k(\cdot, x), k(\cdot, x') \rangle = k(x, x') \quad \forall x, x' \in \mathcal{X}$$

### 2. Abgeschlossenheit des Raumes:

$$k \text{ spannt } \mathcal{H} \text{ auf: } \mathcal{H} = \overline{\text{span}\{k(\cdot, x) \mid x \in \mathcal{X}\}}$$



## Konstruktion eines Merkmalraumes (2)

- ▶ Geg.: Kern  $k(x, x')$  und reproduzierende Merkmalabbildung  $\phi : \mathcal{X} \rightarrow \mathbb{R}^{\mathcal{X}} = \{f : \mathcal{X} \rightarrow \mathbb{R}\}$ ,  $\phi(\cdot) = k(\cdot, x)$
- ▶ Ziel: Vektorraum konstruieren mit  $k$  als Skalarprodukt
  1. Konstruiere Vektorraum aller Linearkombinationen von  $k(\cdot, x)$
  2. Definiere darauf ein Skalarprodukt
  3. Prüfe, ob wirklich Skalarprodukt

## Konstruktion eines Merkmalraumes (3)

- zu 1.: Für  $m \in \mathbb{N}$ ,  $\alpha_i \in \mathbb{R}$  und  $x_i \in \mathcal{X}$  beliebig

$$f(\cdot) = \sum_{i=1}^m \alpha_i k(\cdot, x_i)$$

- zu 2.: Skalarprodukt von  $f$  und  $g(\cdot) = \sum_{j=1}^k \beta_j k(\cdot, x'_j)$ :

$$\langle f, g \rangle := \sum_{i=1}^m \sum_{j=1}^k \alpha_i \beta_j k(x_i, x'_j)$$

## Konstruktion eines Merkmalraumes (4)

- ▶ zu 3.: fast alle Eigenschaften sind offensichtlich
- ▶ noch zu zeigen:  $\langle f, f \rangle = 0 \Rightarrow f = 0$
- ▶ Beweis:  $f(\cdot) = \sum \alpha_i k(\cdot, x_i)$  :

$$\langle k(\cdot, x), f(\cdot) \rangle = \sum \alpha_i k(x_i, x) = f(x)$$

- ▶  $\Rightarrow \langle k(\cdot, x), k(\cdot, x') \rangle = k(x, x')$
- ▶  $|f(x)|^2 = |\langle k(\cdot, x), f(x) \rangle|^2 \leq k(x, x) \cdot \langle f(x), f(x) \rangle$
- ▶  $\Rightarrow 0 \leq |f(x)|^2 \leq k(x, x) \cdot 0 \Rightarrow f(x) = 0$



## Darstellung im Merkmalraum

- ▶ **Theorem von Mercer** gibt Bedingungen an, wann zu einem Kern ein Hilbertraum gefunden werden kann, in dem der Kern ein Skalarprodukt darstellt
- ▶ Liefert Darstellung des RKHS mit einer Standardbasis
- ▶ Interpretation des Theorems:  
Jeder stetige, symmetrische, positiv definite Kern kann als Skalarprodukt in einem höher-dimensionalen Raum ausgedrückt werden
- ▶ Anwendung: „**Kerntrick**“

## Theorem von Mercer (1)

- Ann.: Sei  $\mu$  ein endliches Maß und  $k \in L_\infty(\mathcal{X}^2)$  symmetrisch, stetig und reellwertig, so dass der Integraloperator

$$T_k : L_2(\mathcal{X}) \rightarrow L_2(\mathcal{X})$$

$$(T_k f)(x) := \int_{\mathcal{X}} k(x, x') f(x') d\mu(x')$$

positiv definit ist und so dass  $\forall f \in L_2(\mathcal{X})$  gilt:

$$\int_{\mathcal{X} \times \mathcal{X}} k(x, x') f(x) f(x') d\mu(x) d\mu(x') \geq 0$$

## Theorem von Mercer (2)

- ▶ In dieser Situation gibt es für den Operator  $T_k$  höchstens abzählbar viele nicht-negative Eigenwerten  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_J \geq 0$  und dazugehörige, orthogonale Eigenfunktionen  $\psi_j \in L_2(\mathcal{X})$  ( $J \in \mathbb{N}$  oder  $J = \infty$ )
- ▶ Und es gilt:

$$k(x, x') = \sum \lambda_j \psi_j(x) \psi_j(x') \text{ für fast alle } (x, x')$$

$$\Rightarrow \text{Wahl von } \Phi(x) = (\sqrt{\lambda_1} \psi_1(x), \dots, \sqrt{\lambda_J} \psi_J(x))$$



## „Kerntrick“

- ▶ Methode um lineare Algorithmen in nicht-lineare umzuwandeln
- ▶ Dazu Verwendung von nicht-lineare Funktionen, die die originalen Beobachtungen in höher-dimensionale Merkmalsräume abbilden
- ▶ Anwendungen:
  - ▶ Perceptron Algorithmus
  - ▶ Support Vector Machines
  - ▶ Hauptkomponentenanalyse
  - ▶ ...



## Beispiele

- ▶ Homogener Polynom-Kern:  $k(x, x') = \langle x, x' \rangle^d$
- ▶ Inhomogener Polynom-Kern:  $k(x, x') = (\langle x, x' \rangle + c)^d$
- ▶ S-förmige Kerne:  $k(x, x') = \tanh(\kappa \langle x, x' \rangle + \vartheta)$  mit  $\kappa, \vartheta > 0$

# Inhaltsverzeichnis

## 1. Kerne

1.1 Motivation

1.2 Kerne als Ähnlichkeitsmaße

1.3 Kerne als Nicht-Ähnlichkeitsmaße

## 2. Kostenfunktionale

2.1 Grundlagen

2.2 Testfehler und erwartetes Risiko

2.3 Statistisches Konzept des Kostenfunktionals

2.4 Bewertung von Schätzern

## Kern als Nicht-Ähnlichkeitsmaß

- ▶ Definition: Abbildung

$$k : \mathcal{X} \times \mathcal{X} \rightarrow \mathbb{K}$$

- ▶ mit **Symmetrie-Eigenschaft**

$$\forall x, x' \in \mathcal{X} : k(x, x') = \overline{k(x', x)}$$

- ▶ und **bedingt positiver Definitheit**

$$\sum_{i,j=1}^m (c_i \bar{c}_j k(x_i, x_j)) \geq 0, \forall c_i \in \mathbb{K} \text{ mit } \sum_{i=1}^m c_i = 0 \text{ und } m \geq 2$$



## Interpretation

- ▶ Kerne als Nicht-Ähnlichkeitsmaße ermitteln auch Ähnlichkeit zweier Objekte
- ▶ **Je kleiner** der Wert des **Nicht-Ähnlichkeitsmaßes**, **desto ähnlicher** sind die verglichenen **Objekte**
- ▶ Auch Unähnlichkeitsmaße oder Distanzmaße genannt
- ▶ Eigenschaft: Bedingte positive Definitheit, Symmetrie



## Warum bedingt positiv definite Kerne?

- ▶ größere Klasse als positiv definite Kerne
- ▶ aber es gibt Verbindung zu positiv definiten Kernen
- ▶ manche Kernalgorithmen arbeiten mit ihnen

## Konstruktion von pd Kerne aus bedingt pd Kernen

- ▶ Sei  $x_0 \in \mathcal{X}$  und  $k$  ein bedingt pd Kern auf  $\mathcal{X} \times \mathcal{X}$

$$\Leftrightarrow \tilde{k}(x, x') := \frac{1}{2}(k(x, x') - k(x, x_0) - k(x_0, x') + k(x_0, x_0))$$

ist ein pd Kern

- ▶ Führt zur Hilbertraum-Darstellung für  $\tilde{k}(x, x')$  mit  $\tilde{k}(x, x') = \langle \Phi(x), \Phi(x') \rangle$ , indem man die obige Schreibweise in  $\|\Phi(x) - \Phi(x')\|^2 = \tilde{k}(x, x) - 2\tilde{k}(x, x') + \tilde{k}(x', x')$  einsetzt

## Darstellung von bedingt pd Kerne im Hilbertraum

- ▶ Sei  $k$  ein reellwertiger, bedingt pd Kern auf  $\mathcal{X} \times \mathcal{X}$  dann existiert ein Hilbertraum  $\mathcal{H}$  und eine Abbildung  $\Phi : \mathcal{X} \rightarrow \mathcal{H}$ , so dass

$$\|\Phi(x) - \Phi(x')\|^2 = -k(x, x') + \frac{1}{2}(k(x, x) + k(x', x'))$$

- ▶ Für  $k(x, x) = 0 \quad \forall x \in \mathcal{X}$  gilt dann:

$$\|\Phi(x) - \Phi(x')\|^2 = -k(x, x')$$



# Beispiel

- ▶ Exponential Kern:  $e^{-c\|x-x'\|^\beta}$ ,  $0 \leq \beta \leq 2$
- ▶ Inverser Multiquadratischer Kern:  $k(x, x') = \frac{1}{\sqrt{\|x-x'\|^2 + c^2}}$
- ▶ Multiquadratischer Kern:  $k(x, x') = -\sqrt{\|x-x'\|^2 + c^2}$

# Inhaltsverzeichnis

## 1. Kerne

### 1.1 Motivation

### 1.2 Kerne als Ähnlichkeitsmaße

### 1.3 Kerne als Nicht-Ähnlichkeitsmaße

## 2. Kostenfunktionale

### 2.1 Grundlagen

### 2.2 Testfehler und erwartetes Risiko

### 2.3 Statistisches Konzept des Kostenfunktionals

### 2.4 Bewertung von Schätzern

## Fragestellung

- ▶ Ziel der Lerntheorie: Möglichst gute Klassifikation bzw. Regression
- ▶ Wie kann man dies beurteilen?
- ▶ Warum ist das nicht trivial?
  - ▶ Kosten müssen nicht symmetrisch sein
  - ▶ Kosten können von den Eingabedaten abhängen
  - ▶ Wahrscheinlichkeit für eine Fehlklassifizierung kann berücksichtigt werden
  - ▶ usw.

## Definition des Kostenfunktionals

- ▶ Geg.:  $(x, y, f(x)) \in \mathcal{X} \times \mathcal{Y} \times \mathcal{Y}$
- ▶  $x$ : Lerndaten,  $y$ : Beobachtung,  $f(x)$ : Vorhersage
- ▶  $c : \mathcal{X} \times \mathcal{Y} \times \mathcal{Y} \rightarrow [0, \infty)$
- ▶ mit der Eigenschaft

$$c(x, y, f(x)) = 0 \quad \text{für } y = f(x)$$

- ▶ wird **auch Verlust- oder Risikofunktion** genannt

## Klassifizierung

- ▶ Durch Falschklassifizierung entstehen Kosten
- ▶ Kein Unterschied zw. Klassen und Fehlertypen
  - ▶ Kostenfunktional bei binärer Klassifikation:  $\tilde{c}(x) \equiv 1$
- ▶ Sonst ist  $\tilde{c}(yf(x))$  eine beliebige, nicht-negative Funktion (z.B. bei asymmetrischen Kosten)
  - ▶ Soft Margin Kostenfunktional:  $\tilde{c}(yf(x)) = \max(0, 1 - yf(x))$
  - ▶ Logistisches Kostenfunktional:  $\tilde{c}(yf(x)) = \ln(1 + \exp(-yf(x)))$

# Regression

- ▶ Schätzung der Differenz von  $y - f(x)$  entspricht der Quantität der Falsch-Vorhersage
- ▶ Bekannteste Kostenfunktionale:
  - ▶ Quadratisches Kostenfunktional:  $\check{c}(y - f(x)) = (y - f(x))^2$
  - ▶  $\epsilon$  - unempfindliches Kostenfunktional:  
$$\check{c}(y - f(x)) = \max(|y - f(x)| - \epsilon, 0) = |y - f(x)|_{\epsilon}$$

# Inhaltsverzeichnis

## 1. Kerne

### 1.1 Motivation

### 1.2 Kerne als Ähnlichkeitsmaße

### 1.3 Kerne als Nicht-Ähnlichkeitsmaße

## 2. Kostenfunktionale

### 2.1 Grundlagen

### 2.2 Testfehler und erwartetes Risiko

### 2.3 Statistisches Konzept des Kostenfunktionals

### 2.4 Bewertung von Schätzern

## Testfehler und erwartetes Risiko

- ▶ Ziel: **Finde Methode um** erkannte **Fehler zu minimieren**
- ▶ Ann.: Daten  $(x,y)$  iid mit  $P(x,y)$
- ▶ 1.Fall: Wissen über Testdaten während der Trainingszeit
  - ▶ Minimierung des erwarteten Fehlers auf dieser speziellen Testmenge
- ▶ 2.Fall: kein Wissen über Testdaten während der Trainingszeit
  - ▶ Minimierung des erwarteten Fehlers auf allen möglichen Testmengen

## Definition des Testfehlers

- ▶ Trainingsdaten  $\{x_1, \dots, x_m\}$  mit Zielwerten  $\{y_1, \dots, y_m\}$
- ▶ bekannte Testdaten  $\{x'_1, \dots, x'_k\}$  aus denen  $y'_i, i = 1, \dots, k$ , vorhergesagt werden sollen
- ▶ Minimiere erwarteten Fehler auf Testmenge

$$R_{test}[f] := \frac{1}{k} \sum_{i=1}^k \int_{\mathcal{Y}} c(x'_i, y, f(x'_i)) dP(y|x'_i)$$

- ▶ Problem: rechenintensiv und kompliziert

## Definition des erwarteten Risikos

- ▶ kein Wissen über das Testdaten vereinfacht die Minimierung
- ▶ Minimiere erwarteten Fehler auf allen möglichen Testmengen
- ▶ Minimiere dazu erwartete Kosten bezüglich  $P$  und  $c$

$$R[f] = E[R_{test}[f]] := \int_{\mathcal{X} \times \mathcal{Y}} c(x, y, f(x)) dP(x, y)$$

- ▶ Problem: nur lösbar, wenn  $P(x, y)$  explizit bekannt; alternativ durch empirische Verteilung ersetzen

## Definition des empirischen Risikos

- ▶ Minimiere das empirische Risiko

$$R_{emp}[f] = \frac{1}{m} \sum_{i=1}^m c(x_i, y_i, f(x_i))$$

- ▶ Vorteil: bei gegebenen Testdaten einfach zu berechnen und minimieren

# Inhaltsverzeichnis

## 1. Kerne

### 1.1 Motivation

### 1.2 Kerne als Ähnlichkeitsmaße

### 1.3 Kerne als Nicht-Ähnlichkeitsmaße

## 2. Kostenfunktionale

### 2.1 Grundlagen

### 2.2 Testfehler und erwartetes Risiko

### 2.3 Statistisches Konzept des Kostenfunktionalis

### 2.4 Bewertung von Schätzern

## Statistische Sichtweise

- ▶ Statt (oder zusätzlich zum) erw. Risiko für festes Muster:  
Wunsch nach Wissen über  $P(y|\tilde{x})$
- ▶ Ziel: Berechnung der bedingten Dichte  $p(y|\tilde{x})$
- ▶ Hilfsmittel: **Maximum-Likelihood-Schätzung**  
Liefert Funktion  $f$ , die höchstwahrscheinlich die Daten erzeugt hat, in dem man  $p(y|x, f(x))$  bestimmt und bzgl.  $f$  maximiert

## Wiederholung: Maximum-Likelihood

▶ **Maximum-Likelihood-Funktion:**

$$L((x, y), f) := \prod p(x_i, y_i | f) = \prod p(y_i | x_i, f) p(x_i)$$

▶ **Log-Likelihood-Funktion:**

$$\begin{aligned} \log L((x, y), f) &:= \sum \ln(p(y_i | x_i, f) p(x_i)) \\ &= \sum \ln p(y_i | x_i, f) + \sum \ln p(x_i) \end{aligned}$$

▶ Aus OR bekannt:  $\max f(x) = - \min f(x)$

▶ Somit:

$$\max \log L((x, y), f) = - \min(\sum \ln p(y_i | x_i, f) + \sum \ln p(x_i))$$

▶ Wobei die letzte Summe eine Konstante bzgl. der Maximierung  $f$  ist und weggelassen werden kann

## Kostenfunktional für die Regression

- ▶ Es gilt:

$$\min \sum_{i=1}^m (-\ln(p(y_i|x_i, f))) = \min(R_{emp}[f])$$

wenn  $c(x, y, f(x)) = -\ln(p(y|x, f(x)))$

- ▶ Eindeutiges Minimum existiert selten und nur bei festem  $f(x)$
- ▶ Bei Störung der Funktion  $f$ :

$$c(x, y, f(x)) = -\ln(p_{\xi}(y - f(x)))$$

mit gestörter Dichte  $p_{\xi}$

## Kostenfunktional für die Klassifizierung

- ▶ Bei binäre Klassifizierung ist  $P(y|f(x))$  direkt berechenbar mit

$$c(x, y, f(x)) = -\ln(P(y|f(x)))$$

- ▶ Hier:  $y \in \{-1, 1\} \Rightarrow P(-1|f(x)) = 1 - P(1|f(x))$
- ▶ Möglich:  $P(y|f(x))$  nach Bedarf zu wählen, z.B. als logistische Linkfunktion  $c(x, y, f(x)) = \ln(1 + \exp(-f(x)))$
- ▶ Kostenfunktionale jedoch nicht frei wählbar

# Inhaltsverzeichnis

## 1. Kerne

### 1.1 Motivation

### 1.2 Kerne als Ähnlichkeitsmaße

### 1.3 Kerne als Nicht-Ähnlichkeitsmaße

## 2. Kostenfunktionale

### 2.1 Grundlagen

### 2.2 Testfehler und erwartetes Risiko

### 2.3 Statistisches Konzept des Kostenfunktionals

### 2.4 Bewertung von Schätzern

## Eigenschaften von Schätzern

- ▶ Ann.: **Erwartungstreue** (wobei Verzerrung nicht unbedingt schlechte Eigenschaft)
- ▶ **Varianz** als Größe für die Schätzgenauigkeit (mit Cramer-Rao als untere Schranke)
- ▶ **Effizienz** als Indikator dafür, wie „gestört“ ein Schätzer ist

## Effizienz

- ▶ Definition:

$$e := \frac{1}{\det(I B)}$$

- ▶  $I$  : Fisher-Informationsmatrix
- ▶  $B$  : Kovarianzmatrix von  $\hat{\theta}(Y)$
- ▶ Interpretation: je näher  $e$  an 1 ist, desto kleiner ist die Varianz

## Beispiel für effizienten Schätzer

- ▶ ML-Schätzer ist asymptotisch effizient
- ▶ Aber
  - ▶ bei „kleinem“ Stichprobenumfang gibt es bessere Schätzer
  - ▶ eventuell wahre Dichte nicht bekannt, also großer Fehler möglich
- ▶ Lösung: robuste Schätzer

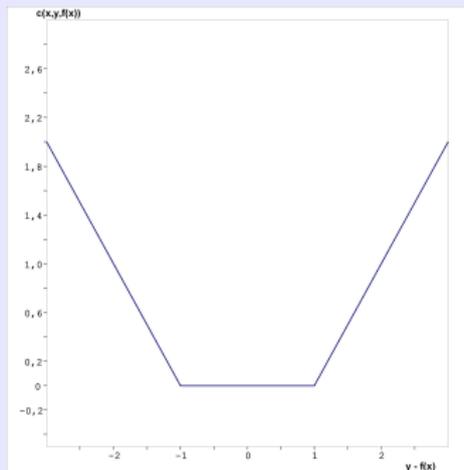
## Robuste Schätzer

- ▶ Ziel: Entfernung des Anteils von „schlechten“ Beobachtungen (sog. Ausreißer), die die Qualität der Schätzung beeinträchtigen
- ▶ **Idee von Huber:** Robuste Schätzer konstruieren, die so modifiziert sind, damit der Einfluss von jedem einzelnen Muster begrenzt ist





## $\epsilon$ - unempfindliches Kostenfunktional



$$c(x, y, f(x)) = |y - f(x)|_{\epsilon}$$

# Fragen

Habt Ihr noch Fragen?

# Fragen

Vielen Dank für eure Aufmerksamkeit

## Quellen

- ▶ B.Schölkopf, A. Smola, „Learning with Kernels“, MIT Press, 2002
- ▶ Vorlesungen von Prof. M. Pawlak, University of Manitoba, Kanada
- ▶ <http://www.learning-with-kernels.org>
- ▶ <http://www.wikipedia.org>