

---

# Kern-Fisher-Diskriminanzanalyse aus analytischer Sicht



**Fraunhofer**

Institut  
Techno- und  
Wirtschaftsmathematik

---

**Dr. Hagen Knaf**

Abteilung      *Adaptive Systeme*

Schwerpunkt      *Entscheidungsunterstützung in  
Medizin und Technik*

---

# Überblick

---



1. Diskriminanzanalyse – Problem und Lösungsansatz
2. Lineare Diskriminanzanalyse nach Fisher
3. Reproduzierende Kerne funktionaler Hilberträume
4. Kern-Fisher-Diskriminanzanalyse
5. Der Algorithmus von S. Mika et. al.
6. Beispiele


**Sir Ronald Aylmer Fisher**, \*1890, London, England, † 1962, Adelaide, Australien

---



Fraunhofer  
Institut  
Techno- und  
Wirtschaftsmathematik

# Diskriminanzanalyse: Das allgemeine Problem



Man betrachtet eine in  $g > 1$  paarweise disjunkte Gruppen unterteilte Grundgesamtheit:

$$\Omega = \Omega_1 \cup \dots \cup \Omega_g$$

Jedem Objekt  $\omega \in \Omega$  sind bestimmte Merkmale

$$x(\omega) \in X$$

zugeordnet.

Finde eine Entscheidungsfunktion

$$e: X \rightarrow \{1, \dots, g\},$$




die jedem  $\omega \in \Omega$  eine vermutete Gruppenzugehörigkeit

$$e(x(\omega))$$

so zuordnet, daß »möglichst wenige« Fehlzuordnungen auftreten.



# Diskriminanzanalyse: Das allgemeine Problem



Aus der unbekanntem Grundgesamtheit zieht man eine (endliche) Stichprobe

$$\Lambda = \Lambda_1 \cup \dots \cup \Lambda_g \subseteq \Omega$$

Basierend auf der Merkmalsmenge

$$Y := \{x(\omega) : \omega \in \Lambda\}.$$

wird eine geschätzte Entscheidungsfunktion

$$\hat{e} : X \rightarrow \{1, \dots, g\}$$




ermittelt.

Gütecharakteristika und Gegenspieler:

- hohe Trefferquote of  $Y$ ,
- verallgemeinerungsfähig auf neue Samples.



# Lösungsansatz: Diskriminanzfunktionen



Vereinfachende Annahmen:  $g = 2, X \subseteq R^m$ .

Betrachte geschätzte Entscheidungsfunktionen der Form:

$$\hat{e}: X \rightarrow \{-1, +1\}, x \mapsto \text{sgn}(d(x)),$$

wobei  $\text{sgn}$  die Signumfunktion und

$$d: X \rightarrow R$$

eine reellwertige Funktion ist – die *Diskriminanzfunktion*.

Die Hyperfläche

$$H := \{x \in R^m : d(x) = 0\}$$

trennt die beiden Gruppen; ihre Elemente bleiben bei strikter Sicht unklassifiziert.

Die Funktion  $d$  wird innerhalb einer Funktionenklasse  $F$  basierend auf den Daten  $Y$  gemäß der Gütekriterien für die Entscheidungsfunktion bestimmt.



# Lineare Diskriminanzanalyse: Fisher's Ansatz

Annahmen:  $g = 2$  (nicht notwendig),  $X \subseteq R^m$  (notwendig),  $Y = Y_{-1} \cup Y_{+1}$ ,  $Y_{-1} \cap Y_{+1} = \{\}$  (notwendig).

Wähle ein lineares Funktional


$$f : R^m \rightarrow R, x \mapsto \langle a, x \rangle$$

so, daß die *Fisherdiskriminante*

$$Q(a) := \frac{(\langle a, \bar{y}_{-1} \rangle - \langle a, \bar{y}_{+1} \rangle)^2}{s_{-1}^2 + s_{+1}^2}$$

maximal wird, wobei  $\bar{y}_k$  Mittelwert von  $Y_k$  ist und:

$$s_k^2 = \sum_{y \in Y_k} (\langle a, y \rangle - \langle a, \bar{y}_k \rangle)^2.$$



---

# Lineare Diskriminanzfunktion

- Fisher's Ansatz liefert die lineare Diskriminanzfunktion:

$$d : R^m \rightarrow R, x \mapsto \langle a, x \rangle + b,$$

$$b = \frac{1}{2} (\langle a, \bar{y}_{-1} \rangle + \langle a, \bar{y}_{+1} \rangle).$$

$$a = W^{-1} (\bar{y}_{-1} - \bar{y}_{+1})$$

$$W = \sum_{k=1}^2 \sum_{y \in Y_k} \langle y - \bar{y}_k, y - \bar{y}_k \rangle$$

- Dieses Ergebnis hat auch eine statistische Interpretation, wenn man geeignete Verteilungsannahmen über die Stichprobendaten macht.



---

# Nichtlineare Diskriminanzfunktionen

**Parametrischer Ansatz:** Betrachte eine parametrisierte Klasse  $F$  von Diskriminanzfunktionen

$$d_p : X \rightarrow R, p \in P$$

und schätze  $p$  aus den Daten.

## Nichtparametrische Methoden:

- Nächste-Nachbar-Methode
- Neuronale Netze
- Klassifikationsbäume
- ...
- Kernmethoden



---

# Funktionale Hilberträume

Im Folgenden werden Hilberträume über dem Körper  $\kappa$  der reellen oder komplexen Zahlen betrachtet.

**Definition:** Der Hilbertraum  $H$  heißt **funktional über der Menge  $X$** , falls er Untervektorraum des Abbildungsraums  $\text{Abb}(X, \kappa)$  (versehen mit der punktweisen Addition und skalaren Multiplikation) ist.

- Für einen funktionalen Hilbertraum  $H$  existieren die linearen Auswertungsfunktionale

$$\varphi_x : H \rightarrow \kappa, f \mapsto f(x) \quad (x \in X).$$

- Die Auswertungsfunktionale sind im unendlich-dimensionalen Fall nicht notwendig stetig.

**Struktursatz:** Ein Hilbertraum ist isomorph zu  $\ell^2(T)$  für geeignetes  $T$  und damit funktional über  $T$ .



---

## Der reproduzierende Kern

**Situation:** Der Hilbertraum  $H$  sei funktional über der Menge  $X$  und besitze stetige Auswertungsfunktionale.

**Riesz'scher Darstellungssatz:**  $\forall x \in X : \exists K_x \in H : \varphi_x = \langle \circ, K_x \rangle$ .

**Definition:** Die Abbildung  $K : X \times X \rightarrow \mathbb{K}$

$$(x, y) \mapsto \langle K_y, K_x \rangle = K_y(x)$$

heißt **reproduzierender Kern von  $H$** .

Sie induziert eine Abbildung

$$\Phi : X \rightarrow H, x \mapsto K(\circ, x) = K_x$$

die injektiv ist, falls  $H$  die Punkte von  $X$  trennt:  $x_1, x_2 \in X : x_1 \neq x_2 \Rightarrow \exists h \in H : h(x_1) \neq h(x_2)$ .

Es gilt die **Schlüsselidentität:**  $\langle \Phi x, \Phi y \rangle = K(y, x)$ .



---

# Eigenschaften des reproduzierenden Kerns

Der reproduzierende Kern  $K$  eines funktionalen Hilbertraums  $H$  über  $X$  besitzt folgende Eigenschaften:

1.  $\forall x, y \in X : K(x, y) = \overline{K(y, x)}$ .
2. Für jede Wahl von paarweise verschiedenen Punkten  $\{x_1, \dots, x_n\} \subseteq X$  ist die Matrix  $A := (K(x_k, x_l))_{k, l \in \{1, \dots, n\}}$  positiv semi-definit:  $\forall z \in \mathbb{K}^n : z^t A \bar{z} \geq 0$ . Beweis
3. Der von den Funktionen  $\{K_x : x \in X\}$  erzeugte Untervektorraum von  $H$  liegt dort dicht. Beweis



---

# Kernfunktionen

**Definition:** Eine Abbildung  $K : X \times X \rightarrow \kappa$  mit den Eigenschaften (1) und (2) der vorangegangenen Folie heißt **Kernfunktion**.

Ist  $X$  ein topologischer Raum, so nennt man eine *stetige* Kernfunktion **Mercer-Kern (\*)**.

**Eigenschaften:** Sind  $K_i : X \times X \rightarrow \kappa, i = 1, 2$ , Kernfunktionen / Mercer-Kerne, so auch:

- die punktweise Summe  $K_1 + K_2$ ,
- positive Vielfache  $\alpha K_1, \alpha > 0$ ,
- die Funktion  $K(x, y) := \overline{f(x)K_1(x, y)f(y)}$  für [stetiges]  $f : X \rightarrow \kappa$ ,
- das punktweise Produkt  $K_1 \cdot K_2$ .

J. Mercer, \*1883 Liverpool, †1932 London.

---



Beispiele von Mercer-Kernen auf  $R^n$  :

- Polynomkern vom Grad  $d$ :  $K(x, y) := (\langle x, y \rangle + c)^d, c > 0,$
- Gaußkern der Bandweite  $h$ :  $K(x, y) := e^{-\frac{\|x-y\|^2}{h^2}}.$
- **Keine** Kernfunktion ist:  $K(x, y) := \tanh(\langle x, y \rangle + c).$



# Das Theorem von Aronzajn-Moore (\*)

**Theorem:** Zu jeder Kernfunktion  $K : X \times X \rightarrow \kappa$  existiert ein über  $X$  funktionaler Hilbertraum, dessen reproduzierender Kern gleich  $K$  ist.

Sind  $H_1, H_2$  über  $X$  funktionale Hilberträume mit reproduzierenden Kernen  $K_1, K_2$ , so gilt:

$$(K_1 = K_2) \Rightarrow (H_1 = H_2).$$


## Bemerkungen:

1. Der durch die Kernfunktion  $K$  eindeutig bestimmte Hilbertraum wird mit  $H(K)$  bezeichnet.
2. Dies ist die Grundlage einer Kategorienäquivalenz zwischen der Kategorie der Kernfunktionen und der Kategorie funktionaler Hilberträume.
3. Anstelle von  $\text{Abb}(X, \kappa)$  können auch interessante Unterräume des vollen Abbildungsraums betrachtet werden, wie zum Beispiel  $r$ -fach stetig differenzierbare oder glatte Funktionen.

Beweisskizze

N. Aronzajn, \*1907 Polen(?), †1980 USA(?).

R.L. Moore, \*1882 Dallas, †1974 Austin.



  
Fraunhofer  
Institut  
Techno- und  
Wirtschaftsmathematik



1 2 3 4 5 6

---

## Bemerkungen zum Theorem von Aronzajn-Moore

- Der Hilbertraum  $H(K)$  ist endlichdimensional, falls  $X$  endlich ist.
- Für jeden Polynomkern auf  $R^n$  ist  $H(K)$  endlichdimensional.
- Für den Gaußkern auf  $R^n$  ist  $H(K)$  unendlichdimensional.
  
- Um nachzuweisen, daß eine gegebene Funktion  $K$  eine Kernfunktion ist, kann die Konstruktion eines funktionalen Hilbertraums  $H$ , dessen reproduzierender Kern  $K$  ist, einfacher / konzeptioneller als ein direkter Beweis sein.

**Beispiel:** Die Tatsache, daß das Produkt  $KK'$  von Kernfunktionen  $K, K'$  auf einer Menge  $X$  eine ebensolche ist,

... kann direkt durch Benutzung der Eigenschaften des Schurprodukts von Matrizen bewiesen werden,

... oder indem man zeigt, daß es der reproduzierende Kern des Tensorprodukts der Hilberträume  $H(K)$  und  $H(K')$  ist.



---

# Kern-Fisher-Diskriminanzanalyse

**Situation:** Gegeben ist eine endliche Stichprobe  $Y = Y_{-1} \cup Y_{+1} \subset R^m$ ,  $Y_{-1} \cap Y_{+1} = \{\}$  einer in zwei Gruppen eingeteilten Grundgesamtheit.

$K : R^m \times R^m \rightarrow R$  sei eine Kernfunktion auf  $R^m$ .

- Der große Definitionsbereich wird zur Klassifikation neuer Samples benötigt.

Im Folgenden arbeitet man in den funktionalen Hilberträumen

$$H(K |_{Y \times Y}) \subseteq H(K)$$

- $H(K |_{Y \times Y})$  wird von den Funktionen  $K_y := K(\cdot, y)$ ,  $y \in Y$  erzeugt.

Man betrachtet weiter die zugehörige Einbettung der Daten

$$\Phi : R^m \rightarrow H(K), y \mapsto K_y,$$

und setzt Injektivität von  $\Phi |_Y$  voraus.



---

# Die Kern-Fisher-Diskriminanzfunktion

**Fakt 1:** Für die eingebettete Stichprobe  $\Phi Y = \Phi Y_{-1} \cup \Phi Y_{+1} \subset H$  läßt sich mittels Fisher's Ansatz eine lineare Diskriminanzfunktion

$$d : H(K_{Y \times Y}) \rightarrow R, x \mapsto \langle a, x \rangle + b$$

bestimmen. Der Pullback

$$d \circ \Phi : R^m \rightarrow R, y \mapsto \langle a, \Phi y \rangle + b$$

ist dann eine Diskriminanzfunktion für die ursprüngliche Stichprobe.

**Subtiler aber wichtiger Punkt:** Das Skalarprodukt  $\langle a, x \rangle$  kann via der natürlichen Inklusion  $H(K|_{Y \times Y}) \subseteq H(K)$  als Skalarprodukt in  $H(K)$  aufgefaßt werden. Die Diskriminanzfunktion  $d$  ist also auf dem eventuell unendlich-dimensionalen Raum  $H(K)$  definiert. Damit können mittels  $d \circ \Phi$  auch neue Samples klassifiziert werden.



---

## Die Kern-Fisher-Diskriminanzfunktion

**Fakt 2:** Die Diskriminanzfunktion  $d \circ \Phi$  lässt sich vollständig in Termini der Kernfunktion  $K$  und der Stichprobendaten  $Y$  ausdrücken.

(In der Literatur wird diese Tatsache häufig als »Kerntrick« bezeichnet.)

Das Element  $a \in H(K|_{Y \times Y})$  hat die Form

$$a = \sum_{y \in Y} \alpha_y \Phi(y), \quad \alpha_y \in R$$

und löst

$$\max_{h \in H(K|_{Y \times Y})} \left( Q(h) := \frac{(\langle h, \bar{h}_{-1} \rangle - \langle h, \bar{h}_{+1} \rangle)^2}{s_{-1}^2 + s_{+1}^2} \right), \quad s_k^2 = \sum_{y \in Y_k} (\langle h, \Phi y \rangle - \langle h, \bar{h}_k \rangle)^2,$$

$\bar{h}_{-1}, \bar{h}_{+1}$  die Mittelwerte der Gruppen  $\Phi Y_{-1}, \Phi Y_{+1}$ .



---

# Die Kern-Fisher-Diskriminanzfunktion

Äquivalent hierzu löst der Vektor  $\alpha := (\alpha_y)_{y \in Y} \in R^n$ ,  $n := |Y|$  das Problem:

$$\max_{\beta \in R^n} \left( Q(\beta) := \frac{\beta^t M \beta}{\beta^t N \beta} \right)$$

$$M = (M_{-1} - M_{+1})(M_{-1} - M_{+1})^t$$

$$(M_i)_y = \frac{1}{n_i} \sum_{y' \in Y_i} K(y, y'), \quad (i = -1, +1)$$

$$N = KK^t - n_{-1}M_{-1}M_{-1}^t - n_{+1}M_{+1}M_{+1}^t$$

$$\alpha = N^{-1}(M_{+1} - M_{-1})$$



---

## Die explizite Kern-Fisher-Diskriminanzfunktion

Hat das Element  $a \in H(K |_{Y \times Y})$  die Form  $a = \sum_{y \in Y} \alpha_y \Phi(y)$  so gilt für die zugehörige Diskriminanzfunktion:

$$d \circ \Phi : R^m \rightarrow R, x \mapsto \sum_{y \in Y} \alpha_y K(y, x) + b.$$

### Probleme

1. Die Berechnung von  $\alpha, b$  aus  $n$  Datenpunkten im  $n$ -dimensionalen Raum ist ein schlecht gestelltes Problem.
2. In realen Data Mining Problemen kann  $n$  sehr groß sein (z.B. Bildverarbeitung).



---

## Der Algorithmus von S.Mika et. al.

- Umformulierung in ein konvexes, quadratisches Optimierungsproblem mit näherungsweise gleicher Lösung:

$$\left. \begin{array}{l} \min_{\alpha, \xi \in R^n, b \in R} (\|\xi\|^2 + C\|\alpha\|^2) \\ K\alpha + \mathbf{1}b = L + \xi \\ \langle \mathbf{1}_+, \xi \rangle = 0 = \langle \mathbf{1}_-, \xi \rangle \end{array} \right\} (P)$$

$\alpha$  : Koordinaten der Lösung

$b$  : konstanter Koeffizient der Fisherfunktion

$K := (K(y_i, y_j))_{i,j} \in R^{n \times n}$ ,  $Y = \{y_1, \dots, y_n\}$

$\mathbf{1} := (1, \dots, 1) \in R^n$

$L \in \{-1, +1\}^n$  Vektor der Gruppenlabels

$\mathbf{1}_+ := \max(L, 0)$ ,  $\mathbf{1}_- := \max(-L, 0)$

$C$  : Regularisierungskonstante

- Kann mit Standardalgorithmen gelöst werden, was aber je nach Stichprobenumfang zeitaufwendig ist.



## Der Algorithmus von S.Mika et. al.

- Die optimale Regularisierung »Anzahl der von 0 verschiedenen Koeffizienten« ist analytisch nicht zu handhaben ...
- ... und liefert die Motivation für einen Algorithmus, der die Anzahl in der Lösung verwendeter Kernfunktionen schrittweise erhöht:

**Start** mit der leeren Menge  $S = \{\}$  von Kernsamples.

**Wahl:** Wähle ein Sample  $y_k \in Y \setminus S$  mit der Optimalitätseigenschaft:

Die Lösung  $\alpha_{S \cup \{y_k\}}, b_{S \cup \{y_k\}}$  des Optimierungsproblems (P) zu der Menge  $S \cup \{y_k\}$  führt zum stärksten Abfall der primären Zielfunktion  $\|\xi\|^2 + C\|\alpha\|^2$  im Vergleich aller Lösungen  $\alpha_{S \cup \{y_l\}}, b_{S \cup \{y_l\}}, y_l \in Y \setminus S$ .

**Abbruch?:** Setze  $S := S \cup \{y_k\}$  und breche ab, falls die Lösungsgüte ausreichend ist, oder gehe zu **Wahl**.



## Der Algorithmus von S.Mika et. al.

• Weshalb geht das alles »schnell«?

- Numerisch sind im Wesentlichen Rang-1-Updates von Matrixinversen und Maxima von quadratischen Polynomen in 2 Variablen zu bestimmen:

$$\min_{a \in \mathbb{R}^{n+1}} \left( \frac{1}{2} a^t H a - c^t a + \frac{n}{2} \right) \quad (P)$$

$$A_+^t a - n_+ = 0 = A_-^t a - n_-$$

$n_+, n_- :=$  Samplezahl von  $Y_+, Y_-$

$$a := \begin{bmatrix} \alpha \\ b \end{bmatrix}$$

$$H := \begin{bmatrix} n & \mathbf{1}^t K \\ K^t \mathbf{1} & K^t K + CE \end{bmatrix}$$

$$a = H^{-1}(c - \lambda_+ A_+ - \lambda_- A_-)$$

$$c := \begin{bmatrix} n_+ - n_- \\ K^t L \end{bmatrix}, \quad A_{+/-} := \begin{bmatrix} n_{+/-} \\ K^t \mathbf{1}_{+/-} \end{bmatrix}$$

$\lambda_+, \lambda_- : \text{Lagrange multiplikatoren von (P)}$




---

## Wahl des Kerns / der Kernparameter

- Der Kernfunktionstyp bzw. die Kernfunktionsparameter werden durch Mika's Algorithmus nicht festgelegt.
- Falls außer der Stichprobe keine Informationen vorliegen ...
  - Schätzung der zu erwartenden Trefferquote (oder eines anderen Gütekriteriums) für eine konkrete Kernfunktion z.B. mittels Kreuzvalidierung,
  - Auswahl derjenigen Kernfunktion mit der höchsten Trefferquote (der höchsten Güte).
- Gefahr des Overfitting ist z.B. bei Gaußkernen mit kleinen Bandbreiten hoch ...
- ... daher Anzahl der Kernfunktionen in einer potentiellen Lösung vorab beschränken.
- Es existieren Algorithmen zur simultanen Kernwahl und Diskriminanzfunktionsbestimmung.



# Datensatz



- 1240 Samples
- 420 in Gruppe -1
- 820 in Gruppe +1



## Erwartete Trefferquoten (10-fache Kreuzvalidierung)

	Lineare Fisher-DA	Kern-Fisher-DA Gaußkern	Kern-Fisher-DA Quadratischer Polynomkern
Gruppe -1	97%	95%	98%
Gruppe +1	89%	99%	97%

Grafik

Grafik

Grafik



---



## Zu den Gütekriterien für Diskriminanzfunktionen

- Kern-Fisher-DA maximiert die Fisherdiskriminante im funktionalen Hilbertraum ...
- ... nicht die gruppenweise / totale Trefferquote ...
- ... was auch nicht unbedingt wünschenswert ist (Generalisierung!) ...
- ... aber durch Nachjustieren der als Trennfläche verwendeten Niveaufläche der Diskriminanzfunktion angestrebt werden kann und wird.
- Angemessenere Gütekriterien werden aktuell diskutiert ...
- ... z.B. die Fläche unter der Receiver-Operating-Characteristic, ein globales Gütemaß, das die Trefferquoten zu den verschiedenen Trennflächen innerhalb einer 1-Parameter-familie erfaßt.
- Exzellenzcluster Klassifikation





# Lineare Fisher-DA

$$d(x) = \langle a, x \rangle + b$$





# Kern-Fisher-DA / Gaußkern

$$d(x) = \sum_{k=1}^5 \alpha_k e^{-\frac{\|x-x_k\|^2}{0.86^2}}$$



# Kern-Fisher-DA/Polynomkern

$$d(x) = \sum_{k=1}^5 \alpha_k (\langle x, x_k \rangle + 0.3)^2$$



---

## Beweis für die Positiv-Semi-Definitheit des reproduzierenden Kerns

$$\begin{aligned} z^t A \bar{z} &= \sum_{i=1}^n \sum_{j=1}^n z_i K(x_i, x_j) \bar{z}_j \\ &= \sum_{i=1}^n \sum_{j=1}^n z_i \langle K_{x_j}, K_{x_i} \rangle \bar{z}_j \\ &= \left\langle \sum_{j=1}^n \bar{z}_j K_{x_j}, \sum_{i=1}^n \bar{z}_i K_{x_i} \right\rangle \geq 0 \end{aligned}$$




---

## Beweis für die Dichtheit des von den Kernfunktionen erzeugten Unterraums

Es genügt zu zeigen, daß einzig der Nullvektor senkrecht auf allen Kernfunktionen steht.

$$\begin{aligned} & \forall x \in X : \langle h, K_x \rangle = 0 \\ \Leftrightarrow & \forall x \in X : h(x) = 0 \\ \Leftrightarrow & h = 0 \end{aligned}$$



---

# Beweisskizze für das Theorem von Aronzajn-Moore / 1

## Existenz

• Betrachte den Vektorraum  $W := \sum_{y \in X} \kappa \cdot K_y \subseteq \text{Abb}(X, \kappa)$ ,  $K_y := K(\circ, y)$ ;

• definiere eine Bi-/Sesquilinearform auf  $W$  durch:

$$b: W \times W \rightarrow \kappa, \quad b\left(\sum_{y \in X} a_y \cdot K_y, \sum_{y' \in X} b_{y'} \cdot K_{y'}\right) := \sum_{y \in X} \sum_{y' \in X} a_y \bar{b}_{y'} \cdot K(y', y) \quad (\text{Summen endlich})$$

•  $b$  ist positiv definit und erfüllt  $b(h, K_y) = h(y)$ .

• Definiere den Hilbertraum  $H$  als Komplettierung von  $(W, b)$ ,

• es gilt dann:  $(h = \lim_{k \rightarrow \infty} w_k, w_k \in W) \Rightarrow (\forall x \in X : \lim_{k \rightarrow \infty} w_k(x) \text{ existiert})$ ,

• damit ist  $H$  via der Auffassung  $h(x) := \lim_{k \rightarrow \infty} w_k(x)$  funktional über  $X$ ,



---


## Beweisskizze für das Theorem von Aronzajn-Moore / 2

- schließlich gilt:  $(h = \lim_{k \rightarrow \infty} w_k, w_k \in W) \Rightarrow (\forall x \in X : \langle h, K_x \rangle = h(x))$ ,
- und damit sind die Auswertungsfunktionale stetig ...
- ... und der reproduzierende Kern von H ist gleich K.

### Lemma

Sei H ein funktionaler Hilbertraum über der Menge X, mit stetigen Auswertungsfunktionalen.

Dann gilt: Normkonvergenz in H impliziert punktweise Konvergenz auf X.



---

## Beweisskizze für das Theorem von Aronzajn-Moore / 3

### Eindeutigkeit

- Betrachte die durch die Kernfunktionen in  $H_1, H_2$  erzeugten Untervektorräume  $W_1, W_2$ ,
- es gilt  $(h = \sum_{k=1}^n a_{y_k} \cdot K_{y_k} \in W_i) \Rightarrow (h(x) = \sum_{k=1}^n a_{y_k} \cdot K_i(x, y_k)) (i = 1, 2),$
- und damit  $W_1 = W_2 =: W.$
- Weiter gilt:  $(h = \sum_{k=1}^n a_{y_k} \cdot K_{y_k} \in W_i) \Rightarrow (\|h\|_i^2 = \sum_{j=1}^n \sum_{k=1}^n a_{y_j} \bar{a}_{y_k} \cdot K_i(y_k, y_j)) (i = 1, 2),$
- und damit:  $\|\circ\|_1 = \|\circ\|_2$  auf  $W.$
- Jedes  $h \in H_1$  ist Limes einer Cauchyfolge  $(w_k)_k$  aus  $W$ ; diese hat einen Grenzwert  $g \in H_2$  womit nach dem Lemma  $h=g$  folgt.
- Es folgt  $H_1 = H_2$  und  $\|\circ\|_1 = \|\circ\|_2$  wegen der Dichtheit von  $W.$

