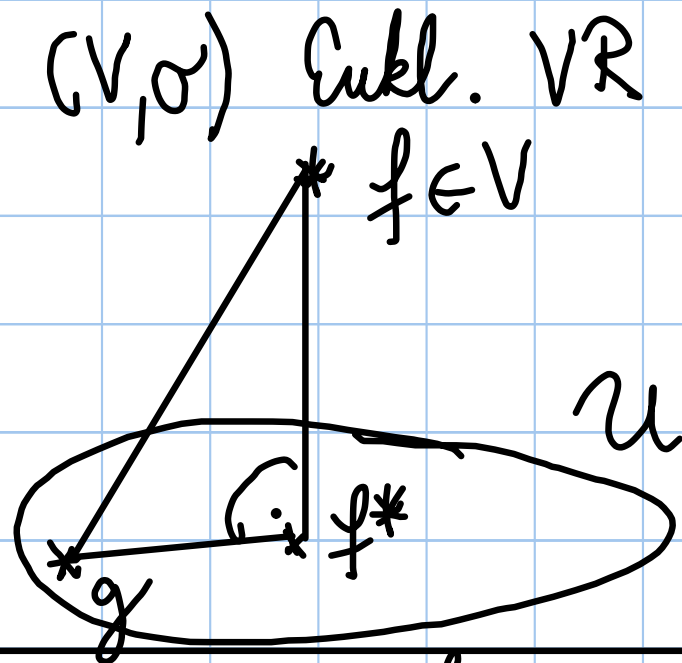


# Diskrete Approximation

## 1) Beste Approximation in Eukl. VR



Def.  $f^* \in U$  beste Approximation von  $f$  in  $U$   
 $\Leftrightarrow \forall g \in U \quad \|f^* - f\| \leq \|g - f\|$

Beste Approximation def. eine lineare Abbildung

$$P: V \longrightarrow U = \langle g_1, \dots, g_n \rangle$$
$$f \longmapsto P(f) := f^*$$

O.É.d.A.  $g_1, \dots, g_n$  ONS  $\Rightarrow$

$$f^* = \sum_{k=1}^n \sigma(f, g_k) g_k$$

Bilinearität von  $\sigma \Rightarrow P$  lineare Abb.

Folgerung  $V = \mathbb{R}^N$ ;  $P$  ist eindeutig  
bestimmt durch  $P(e_i)$ ;  $i=1, \dots, N$ .

## Berechnung der besten Approximation

Sei  $U = \langle g_1, \dots, g_n \rangle$  und

$B = \{g_1, \dots, g_n\}$  linear unabhängig

$$f^* - f \perp U \Leftrightarrow f^* - f \perp g_k \quad k=1, \dots, n$$

$$\Leftrightarrow \sigma(f^* - f, g_k) = 0 \quad k=1, \dots, n$$

$$\Leftrightarrow \sigma(f^*, g_k) = \sigma(f, g_k).$$

$$\text{Sei } f^* = \sum_{i=1}^n \lambda_i g_i \Rightarrow$$

$$f^* - f \perp U \Leftrightarrow \sum_{i=1}^n \lambda_i \sigma(g_i, g_k) = \sigma(f, g_k) \quad k=1, \dots, n$$

(\*) ist eindeutig lösbar  $\Leftrightarrow$

(\*\*)  $\sum_i \lambda_i \sigma(g_i, g_k) = 0 \quad k=1, \dots, n$   
ist eindeutig lösbar.  
i.e.  $\Rightarrow \lambda_i = 0 \quad i=1, \dots, n$

$$(**) \Rightarrow \sum_{i=1}^n \lambda_k \lambda_i \sigma(g_i, g_k) = 0 \quad k=1, \dots, n$$

$$\Rightarrow \sum_{k=1}^n \sum_{i=1}^n \lambda_k \lambda_i \sigma(g_i, g_k) = 0$$

$$\Rightarrow \sigma\left(\sum_i \lambda_i g_i, \sum_k \lambda_k g_k\right) = 0$$

$$\stackrel{\text{pos def.}}{\Rightarrow} \sum_{i=1}^n \lambda_i g_i = 0 \stackrel{\text{l.u. der } g_i}{\Rightarrow} \lambda_i = 0 \quad i=1, \dots, n \quad \square$$

$\Rightarrow$  Beide Approx.  $f^*$  von  $f$  in  $\mathcal{U}$  existiert  
und ist eindeutig!

Beispiele:  $V = C_0(I, \mathbb{R})$   $I = [a, b]$

$$\sigma(f, g) = \int_a^b f(x) g(x) dx$$

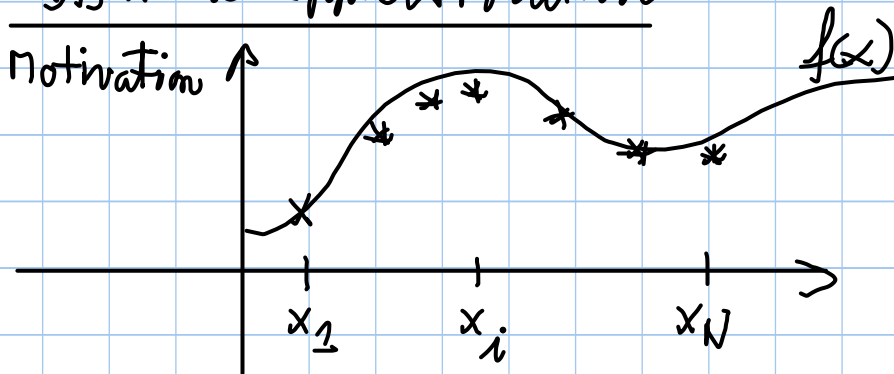
$U = \langle g_1, \dots, g_n \rangle$  mit  $g_i$

1)  $1, x, x^2, \dots$

2)  $1, \sin(kx), \cos(kx)$

# Discrete Approximation

Motivation



Def.  $\bar{(\cdot)} : C_0(I, \mathbb{R}) \longrightarrow \mathbb{R}^N$

$$f \longmapsto \bar{f} := \begin{pmatrix} f(x_1) \\ \vdots \\ f(x_N) \end{pmatrix}$$

Def. geg  $(x_i, y_i) \ i=1, \dots, N \quad x_i \in I \subseteq \mathbb{R}$

u.  $g_1, \dots, g_n \in C_0(I, \mathbb{R})$

$f^* = \sum_{i=1}^n \lambda_i g_i$  heißt beste diskrete

Approximation  $\Leftrightarrow$

$$\forall \quad g \in \langle g_1, \dots, g_n \rangle \quad \|\bar{f}^* - \bar{y}\| \leq \| \bar{g} - \bar{y} \|; \quad \bar{y} = \begin{pmatrix} y_1 \\ \vdots \\ y_N \end{pmatrix}$$

# 'Methode der kleinsten Quadrate' von Gauss

geg.  $(x_i, y_i) \quad i = 1, \dots, N$

$g_i \in C_0(I, \mathbb{R}) \quad i = 1, \dots, n$

Gesucht Fkt  $f^* = \sum_{i=1}^n \lambda_i g_i$  so dass

$$\forall g \in \langle g_1, \dots, g_n \rangle \quad \sum_{i=1}^N (f^*(x_i) - y_i)^2 \leq \sum_{i=1}^N (g(x_i) - y_i)^2$$

d.h.  $\| \bar{f}^* - \bar{y} \|^2 \leq \| \bar{g} - \bar{y} \|^2$

# Berechnung der besten diskreten Approximation

$$\begin{array}{ccc} C_0(I, \mathbb{R}) & \xrightarrow{\bar{(\cdot)}} & \mathbb{R}^N \ni \bar{y} = \begin{pmatrix} y_1 \\ \vdots \\ y_N \end{pmatrix} \\ \uparrow & & \uparrow \\ \langle g_1, \dots, g_n \rangle & \xrightarrow[\text{surj.}]{\bar{(\cdot)}} & \langle \bar{g}_1, \dots, \bar{g}_n \rangle \ni \bar{y}^* \end{array}$$

Schritt 1: Berechne beste Approx. von  $\bar{y}$  in  $\mathcal{U}$   
(existiert und ist eindeutig)

Schritt 2: Sei  $\bar{y}^* := \sum_{i=1}^n \lambda_i \bar{g}_i$ . Dann

ist  $y^* := \sum_{i=1}^n \lambda_i g_i$  beste  
diskrete Approximation.

Beweis. Nach Konstruktion gilt:

$$\bar{f}^* = \bar{y}^* \Rightarrow$$

$$\forall g \in \langle g_1, \dots, g_n \rangle \quad \|\bar{f}^* - \bar{y}\| = \|\bar{y}^* - \bar{y}\| \leq \|\bar{g} - \bar{y}\|,$$

da  $\bar{f}^* = \bar{y}^*$  beste Approx. von  $\bar{y}$  in  $\mathcal{U}$ .

Anwendung: Logistische Regression

## Interpolation

Bezeichnung wie oben

$f^* \in \langle g_1, \dots, g_n \rangle$  heißt Interpolationsfkt.

der  $(x_i, y_i), i=1, \dots, N \Leftrightarrow$

$$\forall_{i=1, \dots, N} f^*(x_i) = y_i$$

$$C_0(I, \mathbb{R}) \xrightarrow{\overline{(\cdot)}} \mathbb{R}^N \ni \overline{y}$$

$$\begin{array}{ccc} \uparrow & \overline{(\cdot)} & \uparrow \\ \langle g_1, \dots, g_n \rangle & \xrightarrow{\quad} & \langle \overline{g}_1, \dots, \overline{g}_n \rangle \end{array}$$

Mit  $f^*$  eine Interpolationsfkt., so gilt

$$\overline{f^*} = \overline{y^*} = \overline{y} \text{ d.h.}$$

Satz geg.  $(x_i, y_i), i=1, \dots, N$  u.  $g_i \in C_0(I, \mathbb{R})$   
 $i=1, \dots, n$

Zu  $(x_i, y_i)$  gibt es eine Interpolationsfkt

$$f^* \in \langle g_1, \dots, g_n \rangle \Leftrightarrow \overline{y} \in \langle \overline{g}_1, \dots, \overline{g}_n \rangle$$

## Hauptsatz der Interpolationstheorie

geg  $(x_i, y_i); i=1, \dots, N+1$   $x_i \neq x_j$   
für  $i \neq j$

Dann existiert genau ein Polynom  $p(x)$   
vom Grade  $\leq N$  mit

$$p(x_i) = y_i \text{ für } i=1, \dots, N$$

Beweis  $C_0(I, \mathbb{R}) \xrightarrow{\overline{(\cdot)}} \mathbb{R}^{N+1} \ni \overline{y}$

$$\langle 1, x, \dots, x^N \rangle \xrightarrow{\cong} \langle \overline{1}, \overline{x}, \dots, \overline{x^N} \rangle$$

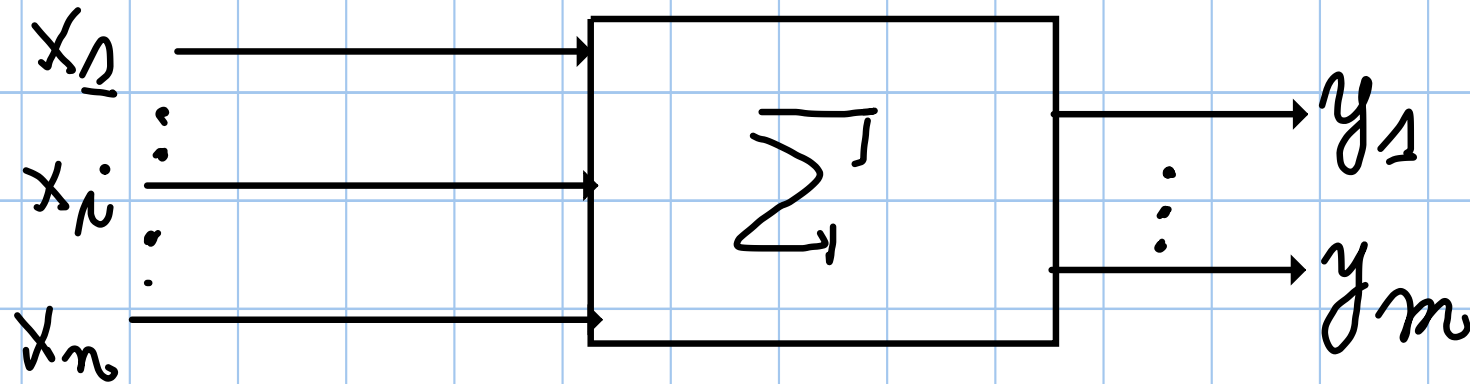
$$x_i \neq x_j; i \neq j \Rightarrow \{ \overline{1}, \overline{x}, \overline{x^2}, \dots, \overline{x^N} \} \text{ l.u.}$$

$$\Rightarrow \langle \overline{1}, \dots, \overline{x^N} \rangle = \mathbb{R}^{N+1} \Rightarrow$$

$$\forall \overline{y} \in \mathbb{R}^{N+1} \quad \overline{y} \in \langle \overline{1}, \dots, \overline{x^N} \rangle \Rightarrow$$
$$f(x) = p(x) = \sum_{k=0}^N \lambda_k x^k \text{ ist}$$

Interpolationspolynom.

# Universalisierung



geg  $(\bar{x}_i, \bar{y}_i) \quad i = 1, \dots, N$

ges. Abbildung  $f^*$  mit  $f^*(\bar{x}_i) = \bar{y}_i$ .

# Interpolationspolynom nach Lagrange

$$L_i(x_j) = \begin{cases} 1 & i=j \\ 0 & \text{sonst.} \end{cases} \quad i, j = 1, \dots, N+1$$

$$L_i(x) := \frac{(x-x_2) \dots (x-x_{i-1})(x-x_{i+1}) \dots (x-x_{N+1})}{(x_i-x_2) \dots (x_i-x_{i-1})(x_i-x_{i+1}) \dots (x_i-x_{N+1})}$$

$$\Rightarrow p(x) := \sum_{i=1}^{N+1} L_i(x) y_i$$

$$\text{Damit gilt: } p(x_j) = \sum_{i=1}^{N+1} L_i(x_j) = y_j$$