

Vorlesung Lernalgorithmen

Support Vector Machines

Stefan Gulan

Lineare Separierbarkeit



- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

- *Hyperebene* H im \mathbb{R}^n definiert durch Normale \mathbf{w} und Skalar b

$$\mathbf{w} \cdot (\mathbf{h} - \mathbf{x}) = \mathbf{w} \cdot \mathbf{h} + b = 0$$

Lineare Separierbarkeit



- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

- *Hyperebene* H im \mathbb{R}^n definiert durch Normale \mathbf{w} und Skalar b

$$\mathbf{w} \cdot (\mathbf{h} - \mathbf{x}) = \mathbf{w} \cdot \mathbf{h} + b = 0$$

- $X, Y \subset \mathbb{R}^n$ heissen *linear separierbar*, wenn sie in verschiedenen Halbräumen von H liegen:

Lineare Separierbarkeit



- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

- *Hyperebene* H im \mathbb{R}^n definiert durch Normale \mathbf{w} und Skalar b

$$\mathbf{w} \cdot (\mathbf{h} - \mathbf{x}) = \mathbf{w} \cdot \mathbf{h} + b = 0$$

- $X, Y \subset \mathbb{R}^n$ heissen *linear separierbar*, wenn sie in verschiedenen Halbräumen von H liegen:

$$\forall x \in X : \mathbf{x} \cdot \mathbf{w} + b < 0, \quad \forall y \in Y : \mathbf{y} \cdot \mathbf{w} + b > 0$$

Lineare Separierbarkeit



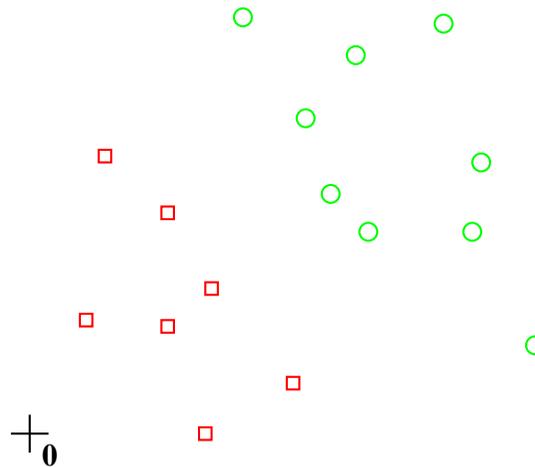
- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

- *Hyperebene* H im \mathbb{R}^n definiert durch Normale \mathbf{w} und Skalar b

$$\mathbf{w} \cdot (\mathbf{h} - \mathbf{x}) = \mathbf{w} \cdot \mathbf{h} + b = 0$$

- $X, Y \subset \mathbb{R}^n$ heissen *linear separierbar*, wenn sie in verschiedenen Halbräumen von H liegen:

$$\forall x \in X : \mathbf{x} \cdot \mathbf{w} + b < 0, \quad \forall y \in Y : \mathbf{y} \cdot \mathbf{w} + b > 0$$



Lineare Separierbarkeit

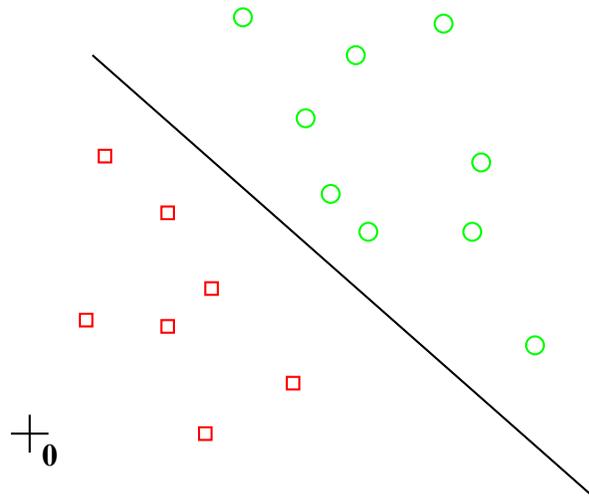
- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

- *Hyperebene* H im \mathbb{R}^n definiert durch Normale w und Skalar b

$$w \cdot (h - x) = w \cdot h + b = 0$$

- $X, Y \subset \mathbb{R}^n$ heissen *linear separierbar*, wenn sie in verschiedenen Halbräumen von H liegen:

$$\forall x \in X : x \cdot w + b < 0, \quad \forall y \in Y : y \cdot w + b > 0$$





Lineare Separierbarkeit

- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

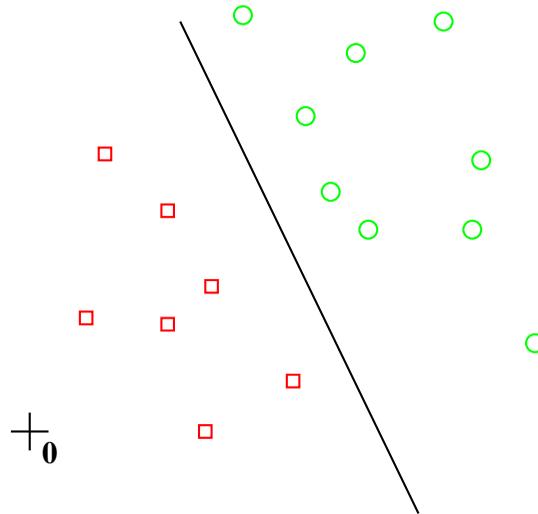
- Lineare Separierbarkeit von X, Y vermöge beliebig vieler H_i

Lineare Separierbarkeit



- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

- Lineare Separierbarkeit von X, Y vermöge beliebig vieler H_i

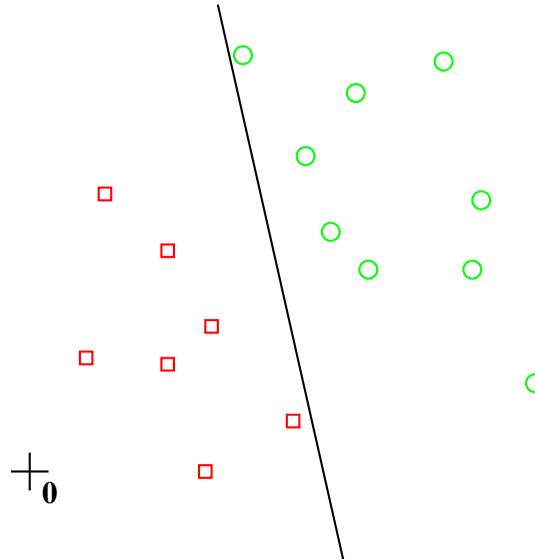


Lineare Separierbarkeit



- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

- Lineare Separierbarkeit von X, Y vermöge beliebig vieler H_i

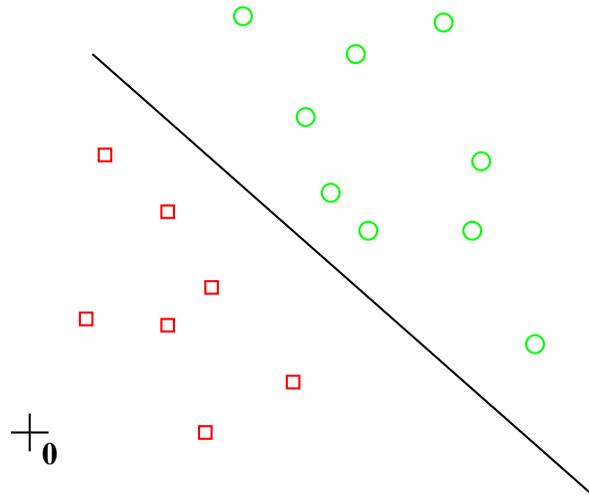


Lineare Separierbarkeit



- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

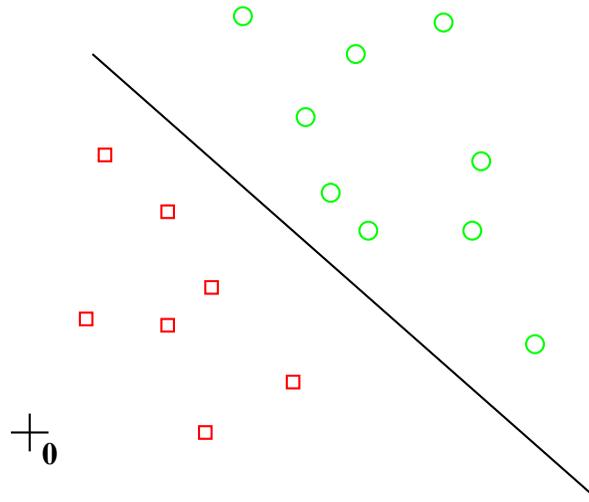
- Lineare Separierbarkeit von X, Y vermöge beliebig vieler H_i



Lineare Separierbarkeit

- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

- Lineare Separierbarkeit von X, Y vermöge beliebig vieler H_i



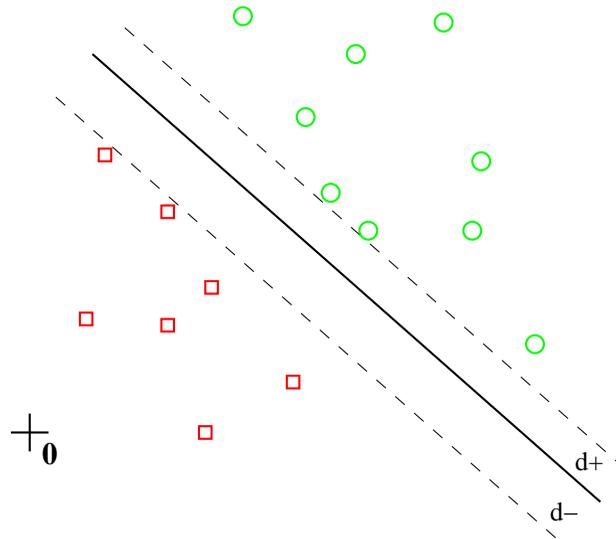
- Abstand v. H zu X, Y heisst *Randweite* (engl. *margin*)

$$d = d_+ + d_-$$

Lineare Separierbarkeit

- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

- Lineare Separierbarkeit von X, Y vermöge beliebig vieler H_i



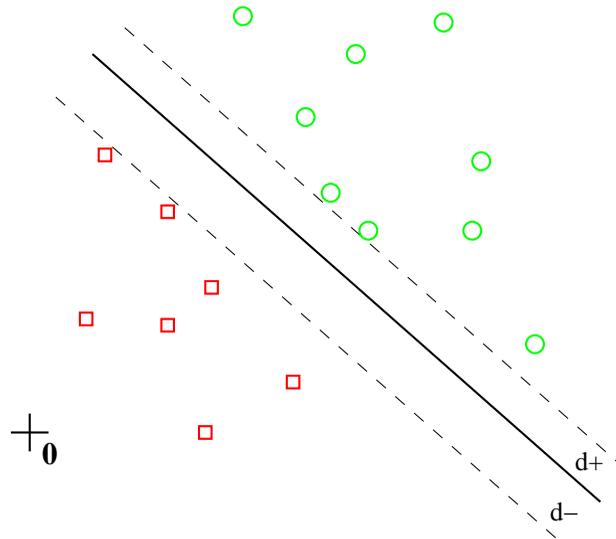
- Abstand v. H zu X, Y heisst *Randweite* (engl. *margin*)

$$d = d_+ + d_-$$

Lineare Separierbarkeit

- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

- Lineare Separierbarkeit von X, Y vermöge beliebig vieler H_i



- Abstand v. H zu X, Y heisst *Randweite* (engl. *margin*)

$$d = d_+ + d_-$$

- Trennung intuitiv besser, je grösser d ist



Formalisierung

- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

- Gegeben: Beispiele $(s_i, l_i) \in (X \times \{+1\}) \cup (Y \times \{-1\})$
Gesucht: trennende Hyperebene (w, b) mit maximalem Rand

Formalisierung



- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

- Gegeben: Beispiele $(s_i, l_i) \in (X \times \{+1\}) \cup (Y \times \{-1\})$
Gesucht: trennende Hyperebene (\mathbf{w}, b) mit maximalem Rand
- Skalierung ermöglicht

$$s_i \cdot \mathbf{w} + b \geq +1 \quad \text{falls } l_i = 1$$

$$s_i \cdot \mathbf{w} + b \leq -1 \quad \text{falls } l_i = -1$$

zusammengefasst: $l_i(s_i \cdot \mathbf{w} + b) \geq 1, \forall i$

Formalisierung

- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

- Gegeben: Beispiele $(s_i, l_i) \in (X \times \{+1\}) \cup (Y \times \{-1\})$
Gesucht: trennende Hyperebene (\mathbf{w}, b) mit maximalem Rand
- Skalierung ermöglicht

$$s_i \cdot \mathbf{w} + b \geq +1 \quad \text{falls } l_i = 1$$

$$s_i \cdot \mathbf{w} + b \leq -1 \quad \text{falls } l_i = -1$$

zusammengefasst: $l_i(s_i \cdot \mathbf{w} + b) \geq 1, \forall i$

- Abstand von H_+, H_- zu H : $d_+ = d_- = \frac{1}{\|\mathbf{w}\|}$
 \Rightarrow Minimierung von $\|\mathbf{w}\|$ maximiert Randweite
 \Rightarrow äquivalent: minimiere $\frac{1}{2} \|\mathbf{w}\|^2 = \frac{1}{2} \mathbf{w} \cdot \mathbf{w}$

Formalisierung

- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

- Gegeben: Beispiele $(s_i, l_i) \in (X \times \{+1\}) \cup (Y \times \{-1\})$
Gesucht: trennende Hyperebene (\mathbf{w}, b) mit maximalem Rand
- Skalierung ermöglicht

$$s_i \cdot \mathbf{w} + b \geq +1 \quad \text{falls } l_i = 1$$

$$s_i \cdot \mathbf{w} + b \leq -1 \quad \text{falls } l_i = -1$$

zusammengefasst: $l_i(s_i \cdot \mathbf{w} + b) \geq 1, \forall i$

- Abstand von H_+, H_- zu H : $d_+ = d_- = \frac{1}{\|\mathbf{w}\|}$
 \Rightarrow Minimierung von $\|\mathbf{w}\|$ maximiert Randweite
 \Rightarrow äquivalent: minimiere $\frac{1}{2}\|\mathbf{w}\|^2 = \frac{1}{2}\mathbf{w} \cdot \mathbf{w}$
- Quadratische Optimierung unter Nebenbedingungen

$$\begin{array}{ll} \text{minimiere} & \frac{1}{2}\|\mathbf{w}\|^2 \\ \text{unter NB} & l_i(s_i \cdot \mathbf{w} + b) \geq 1 \end{array}$$



Verallgemeinerung (1)

- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

- Lineare Separierbarkeit eher unrealistische Annahme



Verallgemeinerung (1)

- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

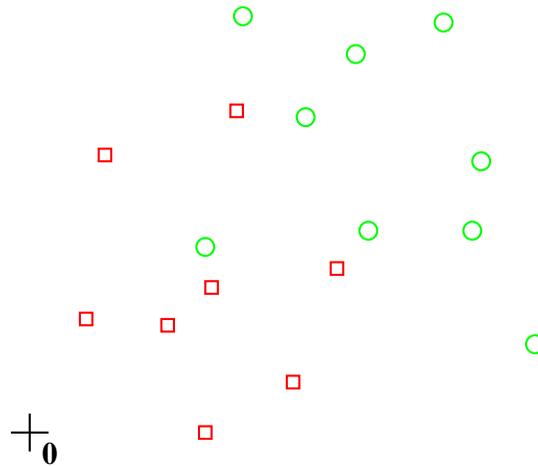
- Lineare Separierbarkeit eher unrealistische Annahme
- Zulassen von Fehlern



Verallgemeinerung (1)

- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

- Lineare Separierbarkeit eher unrealistische Annahme
- Zulassen von Fehlern

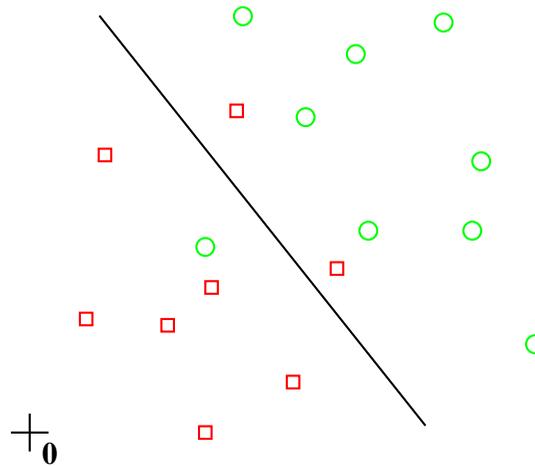




Verallgemeinerung (1)

- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

- Lineare Separierbarkeit eher unrealistische Annahme
- Zulassen von Fehlern

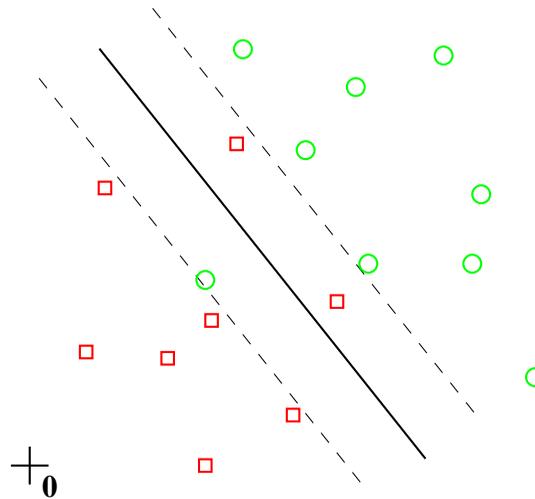




Verallgemeinerung (1)

- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

- Lineare Separierbarkeit eher unrealistische Annahme
- Zulassen von Fehlern

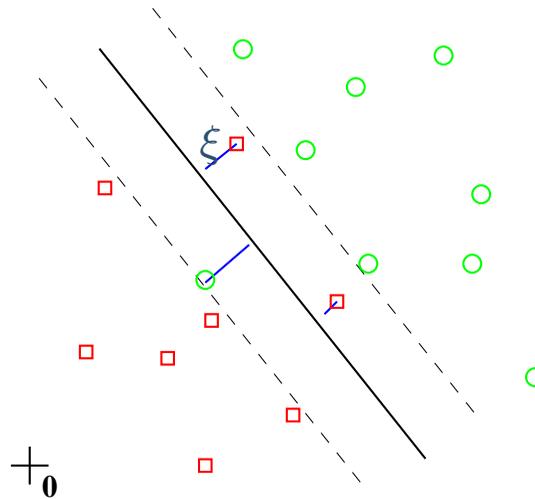




Verallgemeinerung (1)

- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

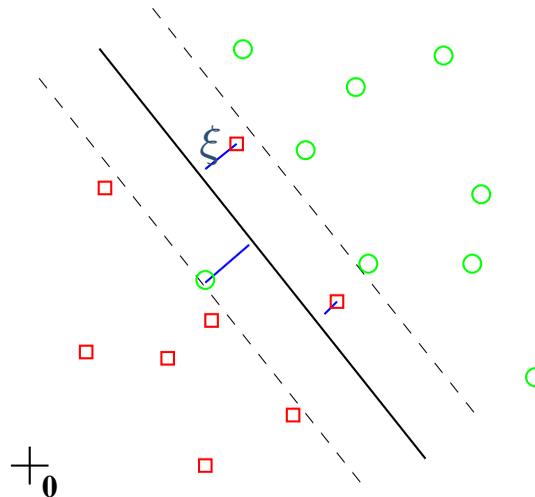
- Lineare Separierbarkeit eher unrealistische Annahme
- Zulassen von Fehlern



Verallgemeinerung (1)

- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

- Lineare Separierbarkeit eher unrealistische Annahme
- Zulassen von Fehlern



- modifiziertes Problem

$$\begin{aligned} \text{minimiere} \quad & \frac{1}{2} \mathbf{w} \cdot \mathbf{w} + C \sum_i \xi_i \quad , C < \infty \\ \text{unter NB} \quad & l_i (\mathbf{s}_i \cdot \mathbf{w} + b) \geq 1 - \xi_i \quad , l_i \in \{-1, +1\} \end{aligned}$$

Lagrange-Dualität



- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

■ Minimierung unter Nebenbedingungen:

$$\begin{array}{ll} \text{minimiere} & f(\mathbf{x}) \\ \text{unter NB} & g_i(\mathbf{x}) \leq 0 \end{array}$$

Lagrange-Dualität

- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

- Minimierung unter Nebenbedingungen:

$$\begin{array}{ll} \text{minimiere} & f(\mathbf{x}) \\ \text{unter NB} & g_i(\mathbf{x}) \leq 0 \end{array}$$

ist äquivalent zu Maximierung des *Lagrange-Dualen*

$$L(\mathbf{x}, \lambda) = f(\mathbf{x}) - \sum_i \lambda_i g_i(\mathbf{x})$$

Lagrange-Dualität

- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

- Minimierung unter Nebenbedingungen:

$$\begin{array}{ll} \text{minimiere} & f(\mathbf{x}) \\ \text{unter NB} & g_i(\mathbf{x}) \leq 0 \end{array}$$

ist äquivalent zu Maximierung des *Lagrange-Dualen*

$$L(\mathbf{x}, \lambda) = f(\mathbf{x}) - \sum_i \lambda_i g_i(\mathbf{x})$$

- hier ist

$$f(\mathbf{x}, \xi) = \frac{1}{2} \mathbf{x} \cdot \mathbf{x} + C \sum_i \xi_i, \quad g_i(\mathbf{x}, \xi_i) = l_i(\mathbf{s}_i \cdot \mathbf{x} + b) + \xi_i - 1$$

also

$$\begin{aligned} L(\mathbf{x}, \xi, \lambda) &= \frac{1}{2} \mathbf{x} \cdot \mathbf{x} + C \sum_i \xi_i \\ &\quad - \sum_i \lambda_i (l_i(\mathbf{s}_i \cdot \mathbf{x} + b) + \xi_i - 1) - \sum \beta_i \xi_i \end{aligned}$$



Verallgemeinerung (2)

- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

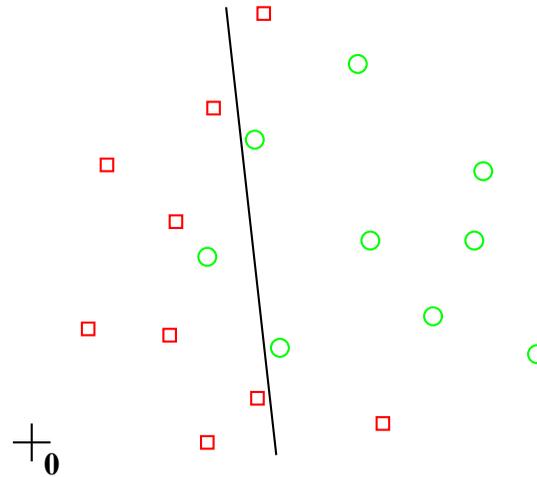
■ Linearität immer noch unrealistisch



Verallgemeinerung (2)

- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

■ Linearität immer noch unrealistisch

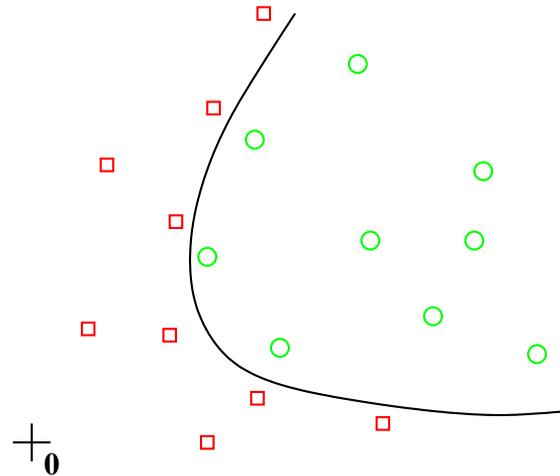




Verallgemeinerung (2)

- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

■ Linearität immer noch unrealistisch



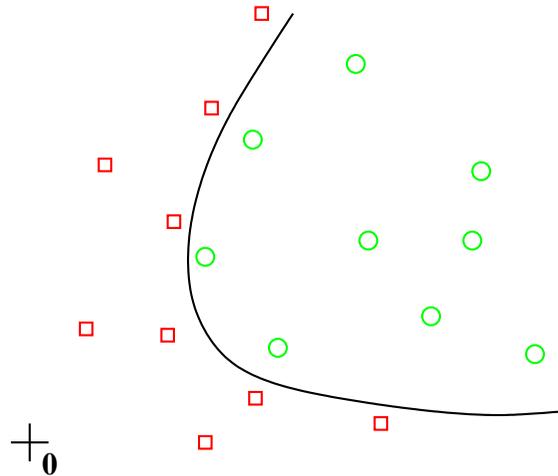
■ Trennung durch nichtlineare Hyperkurve häufig natürlicher



Verallgemeinerung (2)

- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

■ Linearität immer noch unrealistisch



- Trennung durch nichtlineare Hyperkurve häufig natürlicher
- Idee: suche trennende Hyperebene in Raum höherer Dimension (*feature space*)
zunächst $\Phi : \mathbb{R}^n \rightarrow \mathbb{R}^{n+k}$, dann lineare Lsg. in \mathbb{R}^{n+k}



Formalisierung

- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

■ Primaldarstellung:

$$\begin{array}{ll} \text{minimiere} & \frac{1}{2} \Phi(\mathbf{w}) \cdot \Phi(\mathbf{w}) + C \sum_i \xi_i \\ \text{unter NB} & l_i(\Phi(s_i) \cdot \Phi(\mathbf{w})) \leq 1 - \xi_i \end{array}$$

Formalisierung

- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

■ Primaldarstellung:

$$\begin{aligned} \text{minimiere} \quad & \frac{1}{2} \Phi(\mathbf{w}) \cdot \Phi(\mathbf{w}) + C \sum_i \xi_i \\ \text{unter NB} \quad & l_i(\Phi(s_i) \cdot \Phi(\mathbf{w})) \leq 1 - \xi_i \end{aligned}$$

■ Dualdarstellung

$$\begin{aligned} \text{maximiere} \quad L = \quad & \frac{1}{2} \Phi(\mathbf{w}) \cdot \Phi(\mathbf{w}) + C \sum_i \xi_i \\ & - \sum_i \lambda_i (l_i(\Phi(\mathbf{s}_i) \cdot \Phi(\mathbf{w}) + b) + \xi_i - 1) - \sum \beta_i \xi_i \end{aligned}$$

Formalisierung

- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

■ Primaldarstellung:

$$\begin{aligned} \text{minimiere} \quad & \frac{1}{2} \Phi(\mathbf{w}) \cdot \Phi(\mathbf{w}) + C \sum_i \xi_i \\ \text{unter NB} \quad & l_i(\Phi(\mathbf{s}_i) \cdot \Phi(\mathbf{w})) \leq 1 - \xi_i \end{aligned}$$

■ Dualdarstellung

$$\begin{aligned} \text{maximiere} \quad L = \quad & \frac{1}{2} \Phi(\mathbf{w}) \cdot \Phi(\mathbf{w}) + C \sum_i \xi_i \\ & - \sum_i \lambda_i (l_i(\Phi(\mathbf{s}_i) \cdot \Phi(\mathbf{w}) + b) + \xi_i - 1) - \sum \beta_i \xi_i \end{aligned}$$

■ Substitution partieller Ableitungen ($\frac{\partial L}{\partial [\cdot]} = 0$ f. Maximum) und KKT-Bedingungen

$$\text{maximiere} \quad L_d(\lambda) = \sum_i \lambda_i - \frac{1}{2} \sum_{i,j} l_i l_j \lambda_i \lambda_j \Phi(\mathbf{s}_i) \cdot \Phi(\mathbf{s}_j)$$



Kernelfunktionen

- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

■ Eingangsdaten treten in $\Phi(s_i) \cdot \Phi(s_j)$ auf

Kernelfunktionen



- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

- Eingangsdaten treten in $\Phi(s_i) \cdot \Phi(s_j)$ auf
- Φ kann evtl. nach \mathbb{R}^N abbilden ... benötigt wird jedoch „nur“ Skalarprodukt von Bildern von Φ

Kernelfunktionen



- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

- Eingangsdaten treten in $\Phi(s_i) \cdot \Phi(s_j)$ auf
- Φ kann evtl. nach \mathbb{R}^N abbilden ... benötigt wird jedoch „nur“ Skalarprodukt von Bildern von Φ
- Gewünscht ist *Kernelfunktion*

$$k : (X \cup Y)^2 \rightarrow \mathbb{N}, \quad (s_i, s_j) \mapsto \Phi(s_i) \cdot \Phi(s_j)$$

die explizite Berechnung von Φ umgeht

Kernelfunktionen

- Lineare Separierbarkeit
- Lineare Separierbarkeit
- Formalisierung
- Verallgemeinerung (1)
- Lagrange-Dualität
- Verallgemeinerung (2)
- Formalisierung
- Kernelfunktionen

- Eingangsdaten treten in $\Phi(s_i) \cdot \Phi(s_j)$ auf
- Φ kann evtl. nach \mathbb{R}^N abbilden ... benötigt wird jedoch „nur“ Skalarprodukt von Bildern von Φ
- Gewünscht ist *Kernelfunktion*

$$k : (X \cup Y)^2 \rightarrow \mathbb{N}, \quad (s_i, s_j) \mapsto \Phi(s_i) \cdot \Phi(s_j)$$

die explizite Berechnung von Φ umgeht

- Oft auch umgekehrte Problemstellung: Gegeben $f : M^2 \rightarrow \mathbb{N}$, ist f Kernelfunktion? — d.h. existiert Φ , so dass $f(a, b) = \Phi(a) \cdot \Phi(b)$?