

# Quadratische Programmierung

---


Quadratische Optimierung unter  
Nebenbedingungen und ihre  
Anwendung mit SVM's



## Inhalt

---

- Definitionen
- Allgemeiner (Nichtlinearer) Optimierer
- Quadratische Optimierung
- Umsetzung: Active Set Method
- Anwendbarkeit für SVM
- Sequential Minimal Optimization (SMO)
- Zusammenfassung
- Literatur



# Einführung

## Anwendungsgebiete der Optimierung

- Mathematik (Lösung von DGL, ...)
- Physik (Energiminimierung, Statik, ...)
- Wirtschaft (Portfolio-Optimierung, ...)
- Mustererkennung
- ...



# Definitionen

## Allgemeine (Nichtlineare) Optimierungsprobleme

Ein allgemeines Optimierungsproblem lässt sich folgendermaßen mathematisch formulieren:

$$\begin{array}{l}
 \text{Minimiere} \\
 \text{Unter Nebenbedingungen}
 \end{array}
 \begin{array}{l}
 f(\vec{x}) \\
 \left. \begin{array}{l} h_1(\vec{x})=0 \\ \vdots \\ h_m(\vec{x})=0 \end{array} \right\} \Leftrightarrow \vec{h}(\vec{x})=\vec{0} \\
 \left. \begin{array}{l} g_1(\vec{x})\leq 0 \\ \vdots \\ g_r(\vec{x})\leq 0 \end{array} \right\} \Leftrightarrow \vec{g}(\vec{x})\leq \vec{0}
 \end{array}
 \quad \vec{x} \in E^n$$

$f(\vec{x})$  ist die zu minimierende **Zielfunktion**  
 $h_i(\vec{x})=0$  sind sog. **Gleichheitsbedingungen**  
 $g_j(\vec{x})\leq 0$  sind sog. **Ungleichheitsbedingungen**

## Definitionen


Verträglichkeit (*Feasibility*) von Vektoren & Aktivität von Nebenbedingungen

- Ein Vektor  $\vec{x} \in E^n$  ist **verträglich**, wenn er alle Nebenbedingungen erfüllt.
- Eine Nebenbedingung  $g_i(\vec{x}) \leq 0$  ist **aktiv** für einen verträglichen Vektor  $\vec{x} \in E^n$  genau dann, wenn gilt  $g_i(\vec{x}) = 0$ .


5

## Definitionen

Verträglichkeit & Aktive Nebenbedingungen



6



## Definitionen

### Tangentialebenen auf den Nebenbedingungen

- Für jeden verträglichen Vektor  $\vec{x} \in E^n$  definieren seine aktiven Nebenbedingungen **Oberflächen** im Raum. Sind diese differenzierbar ist die zugehörige **Tangentialebene** durch  $\vec{x}$  definiert als:

$$M = \left\{ \vec{y} \mid \vec{\nabla} h(\vec{x}) \vec{y} = 0 \wedge \vec{\nabla} \vec{g}_{aktiv}(\vec{x}) \vec{y} = 0 \right\}$$

7



## Nichtlineare Optimierung

### Allgemeines Vorgehen

Eine iterative Optimierung läuft im Allgemeinen folgendermaßen ab:


- Starte in einem Punkt der alle Nebenbedingungen erfüllt
- **Ermittle eine Richtung**, entlang derer eine sog. *Abstieg*sfunktion (z.B. Gradient) minimal und negativ ist. Gibt es keine solche Richtung: STOP
- **Bestimme entlang dieser Richtung das Minimum** (*line-search*) unter Berücksichtigung der Nebenbedingungen (1D-Optimierung)
- **Wiederhole** die letzten beiden Schritte

8

# Lagrangeansatz

## Lagrange-multiplikatoren

Allgemeine Lagrange-Bedingungen:



$$\begin{aligned}\vec{\nabla} f(\bar{x}^*) + \vec{\lambda}^T \vec{\nabla} h(\bar{x}^*) + \vec{\mu}^T \vec{\nabla} \vec{g}(\bar{x}^*) &= \vec{0} \\ \mu^T \vec{g}(\bar{x}^*) &= \vec{0} \quad \text{und} \quad \vec{\lambda}, \vec{\mu} \geq \vec{0} \\ h(\bar{x}^*) &= \vec{0} \quad \vec{g}(\bar{x}^*) \leq \vec{0}\end{aligned}$$

9

# Quadratische Optimierung

## Grundlagen

Das quadratische Optimierungsproblem hat folgende Form:

$$\begin{array}{ll}\text{Minimiere} & \frac{1}{2} \bar{x}^T Q \bar{x} + \bar{c}^T \bar{x} \\ \text{Unter Nebenbedingungen} & \bar{a}_i^T \bar{x} = b_i \quad i \in E \\ & \bar{a}_i^T \bar{x} \leq b_i \quad i \in I\end{array}$$

Dabei ist  $Q$  *symmetrisch* und *positiv semidefinit*.  
 $I$  und  $E$  sind Indexmengen über Gleichheits-  
und Ungleichheitsbedingungen

10



# Quadratische Optimierung

## Eigenschaften

- Die quadratische **Zielfunktion ist konvex**, das heißt jedes Minimum der eingeschränkten Funktion ist globales Minimum
- Die Nebenbedingungen definieren ein **konvexes Gebiet**
- Die notwendige Bedingung für das globale Optimum mit Lagrange Multiplikatoren ist **linear!**

11



# Quadratische Optimierung

## Bedingungen für ein Optimum


Die Bedingungen für das Optimum (ohne Ungleichheitsbedingungen) lauten dann:

$$Q\vec{x} + A^T \vec{\lambda} + \vec{c} = \vec{0}$$

$$A\vec{x} - \vec{b} = \vec{0}$$

Man erhält ein LGS in  $(n+m)$   
Unbekannten mit  $(n+m)$  Gleichungen

12



## Quadratische Optimierung

### Lösungsformel


---

Mit etwas Rechnerei erhält man folgende explizite Lösungsformel:

$$\vec{x} = Q^{-1} A^T (A Q^{-1} A^T)^{-1} (A Q^{-1} \vec{c} + \vec{b}) - Q^{-1} \vec{c}$$

Aber was machen wir mit den Ungleichheitsbedingungen?

13



## Active Set Method


### Idee

---

Die Idee ist einfach:

Betrachte nur Aktive Untermengen (Working sets) der Nebenbedingungen, dadurch reduziert sich das Problem auf den explizit lösbaren Fall.

14



## Active Set Method


### Vorbemerkung

---

Sei  $W_k$  ein Working set bestehend aus Gleichheitsbedingungen und  $\vec{x}_k$  ein verträglicher Vektor, dann lässt sich folgendes Problem Lösen:

$$\begin{array}{l} \text{Minimiere} \quad \frac{1}{2} \vec{d}_k^T Q \vec{d}_k + (\vec{c} + Q \vec{x}_k) \vec{d}_k \\ \text{unter} \quad \vec{a}_i^T \vec{d}_k = 0 \quad i \in W_k \end{array}$$

15



## Active Set Method

### Vorbemerkung 2

---

Die vorangegangene Optimierung bestimmt die Richtung des nächsten Schritts. Wie weit man nun gehen kann definiert folgende Formel:

$$\alpha_k = \min_{\vec{a}_i^T \vec{d}_k > 0} \left\{ 1, \frac{b_i - \vec{a}_i^T \vec{x}_k}{\vec{a}_i^T \vec{d}_k} \right\}$$

16

# Active Set Method

## Algorithmus

- Bestimme die Richtung des nächsten Schritts
  - Falls  $\vec{d}_k = \vec{0}$  gehe zu Schritt 3
- Setze  $\vec{x}_{k+1} = \vec{x}_k + \alpha_k \vec{d}_k$ 
  - Falls  $\alpha_k < 1$  nimm die neue aktive Nebenbedingung in  $W_{k+1}$  auf.
  - Erhöhe  $k$ , Gehe zu Schritt 1
- Berechne den kleinsten Lagrangemultiplikator der Richtungsformel  $\lambda_q$ 
  - Falls  $\lambda_q \geq 0$  stop.
  - Ansonsten entferne die entspr. Nebenbedingung aus  $W_k$  und setze bei Schritt 1 fort


17

# Active Set Method


## Beispiel

Minimiere  $2x^2 + xy + y^2 - 12x - 10y$   
unter  $x + y \leq 4$   
 $-x \leq 0$   
 $-y \leq 0$

Verträgliches Gebiet



18



## Andere Methoden

Neben der Vorgestellten Active Set Method steht einem Entwickler eine ganze Palette von Alternativen zur Verfügung:

- (Modifizierte) *Gradientenverfahren*
- *Konjugierte Richtungen*
- (Quasi-) *Newton-Verfahren*
- ...

19



## Anwendbarkeit für SVM

Eigenschaften der numerischen Verfahren

- Active Set Method
  - Speicherbedarf in  $O(n^2)$  zur Speicherung der Matrix  $Q$ .
  - Hoher Rechenaufwand zur Bestimmung der Inversen im Richtungs-Such-Schritt
- Mögliche „Zusatzkosten“
  - Hessematrizen (Newton)
  - Eigenwerte und -vektoren (Konjugierte Richtungen)

20

## Anwendbarkeit für SVM

### Wiederholung

SVM-spezifisches Quadratisches OP:

$$\begin{array}{l} \text{Minimiere} \quad \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N y_i y_j K(\bar{x}_i, \bar{x}_j) \alpha_i \alpha_j - \sum_{i=1}^N \alpha_i \\ \text{unter} \quad \quad \quad 0 \leq \alpha_i \leq C \quad \forall i \\ \quad \quad \quad \sum_{i=1}^N y_i \alpha_i = 0 \end{array}$$

Mit Entscheidungsfunktion:

$$u = \sum_{j=1}^N y_j \alpha_j K(\bar{x}_j, \bar{x}) + b$$

21

## Anwendbarkeit für SVM


### Hinreichende Bedingungen

Die Lösung ist optimal genau dann, wenn alle Trainingsbeispiele die sog. Karush-Kuhn-Tucker (KKT) Bedingungen erfüllen:


$$\alpha_i = 0 \Rightarrow y_i u_i \geq 1$$

$$0 < \alpha_i < C \Leftrightarrow y_i u_i = 1$$

$$\alpha_i = C \Rightarrow y_i u_i \leq 1$$



22




## Anwendbarkeit für SVM

### Zahlenbeispiel

# Trainingsbeispiele	Speicherbedarf für Q
100	80 kB
1000	8 MB
2000	32 MB
5000	200 MB
10000	800 MB
20000	6.4 GB

23




## Anwendbarkeit für SVM

### Schlussfolgerung

Da numerische Optimierer die Matrix Q benötigen (möglicherweise noch wesentlich mehr), ist ihr Einsatz mit Supportvektormaschinen impraktikabel!

24



## Spezielle Verfahren für SVM


### Dekomposition

---

Dekomposition beschreibt die Zerlegung des Problems in Subprobleme kleinerer Dimension

Dies erfordert aber eine äußere Iteration, in der das Optimum des vollständigen Problems bestimmt wird

25



## Spezielle Verfahren für SVM

### SMO - Grundlagen

---

#### Osuna's Theorem

Ein großes quadratisches Problem kann in eine Folge von Subproblemen zerlegt werden, solange in jedem Schritt zumindest ein Beispiel, dass die KKT Bedingungen verletzt, hinzugenommen wird.

26

# Spezielle Verfahren für SVM

## SMO – Sequential Minimal Optimization (Platt)


- Idee:
  - Löse eine Sequenz minimaler Subprobleme
    - Da die Gleichheitsbedingung immer erfüllt sein muss, müssen mindestens 2 Lagrangemultiplikatoren simultan optimiert werden
- Umsetzung:
  - Wähle heuristisch in jedem Schritt 2 Lagrangemultiplikatoren
  - Berechne analytisch die optimalen Werte dieser Multiplikatoren

27

# Spezielle Verfahren für SVM


## Subprobleme

Die zu lösenden Subprobleme haben folgende einfache Gestalt:



Zu ihrer Lösung benötigt man nur die beteiligten Samples!

28




## Spezielle Verfahren für SVM

### SMO - Eigenschaften

- Beliebige große Trainingsmengen können trainiert werden
- Keine komplizierten Optimierungen
  - Schneller
  - Genauer
- Sehr viele Iterationen ( $O(n^2)$ )  
(Das gleicht sich durch die schnelle Berechnung innerhalb einer Iteration wieder aus)

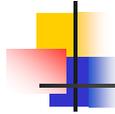
29



## Zusammenfassung

- Optimierung ist ein iterativer Prozess, der in (kleinen) Schritten gegen das Optimum konvergiert
- Konventionelle Verfahren haben sehr hohen Speicheraufwand und sind für große Probleme impraktikabel
- SVM nutzen die Zerlegbarkeit des zugrundeliegenden quadratischen Problems in verschiedenen Implementationen verschieden gut aus

30



## Literatur

---

Zur allgemeinen numerischen Optimierung:

**David G. Luenberger**    *Linear and Nonlinear Programming*  
2nd Edition    Addison-Wesley (1984)

Zu den speziellen SVM Verfahren:

**John C. Platt**    *Technical Report MSR-TR-98-14*  
*Sequential Minimal Optimization*

31



## Lagrange

Idee

---

Voraussetzung:  $f$ ,  $g$  und  $h$  stetig differenzierbar

■ Idee:

- Betrachtet man die Tangentialebene im Optimum, erkennt man, dass der Gradient der Zielfunktion senkrecht auf dieser Tangentialebene steht (Projektion des Optimums der Zielfunktion auf die Nebenbedingungen)
- Daraus folgt, dass der Gradient der Zielfunktion eine Linearkombination der Gradienten der aktiven Bedingungen ist!

32



## Lagrange

### Bedingungen

- Daraus ergibt sich folgende notwendige Bedingung für ein lokales Optimum:

$$\begin{aligned}\vec{\nabla}f(\vec{x}^*) + \vec{\lambda}^T \vec{\nabla}h(\vec{x}^*) + \vec{\mu}^T \vec{\nabla}g(\vec{x}^*) &= \vec{0} \\ \mu^T \vec{g}(\vec{x}^*) &= \vec{0} \quad \text{und} \quad \vec{\lambda}, \vec{\mu} \geq \vec{0} \\ \vec{h}(\vec{x}^*) &= \vec{0} \quad \vec{g}(\vec{x}^*) \leq \vec{0}\end{aligned}$$

$\vec{\lambda}, \vec{\mu}$  sind die Koeffizientenvektoren  
= Lagrangemultiplikatoren

33




## Spezielle Verfahren für SVM

### Chunking (Vapnik)

- Idee
  - Sparse Darstellung der Lösung ausnutzen
    - Da nur Supportvektoren Einfluss auf die Lösung haben, reduziere das Problem auf die Supportvektoren
- Umsetzung
  - Löse in jedem Schritt ein Teilproblem, dass alle potentiellen Supportvektoren des letzten Schritts enthält.
  - Entferne neu gefundene Nicht-Supportvektoren
  - Füge dafür neue Vektoren hinzu, die die KKT-Bedingungen (erheblich) verletzen

34



## Spezielle Verfahren für SVM

### Chunking - Nachteile

---

- Ist die Zahl der Supportvektoren für das Problem groß, ergibt sich das gleiche Problem wie zuvor
- Man benötigt in jedem Schritt eine aufwendige numerische Optimierung