

カーネル法入門

4. SVMの最適化

福水健次


統計数理研究所／総合研究大学院大学



大阪大学大学院基礎工学研究科・集中講義

2014 September

- 最適化問題の双対問題の一般論
- サポートベクターマシンの最適化とサポートベクター




双対問題の一般論


凸集合と凸関数

■ 凸集合

定義. ベクトル空間 V の部分集合 E が凸 (convex) であるとは、任意の2点 $x, y \in E$ と $t \in [0, 1]$ に対し、 $tx + (1 - t)y \in E$ となることをいう。



convex set




non-convex set

■ 凸関数／凹関数


定義 ベクトル空間 V の凸部分集合 E 上定義された関数 $f: E \rightarrow R$ が **凸 (convex)** であるとは、任意の任意の2点 $x, y \in E$ と $t \in [0, 1]$ に対し、

$$f(tx + (1 - t)y) \leq tf(x) + (1 - t)f(y)$$

となることをいう。 $-f$ が凸関数の場合、 f を **凹関数** という。



convex function
凸関数



concave function
凹関数

Lagrange 双対問題

- 主問題 (凸性は仮定しない)

$$\min_{x \in D} f(x) \quad \text{subject to} \quad \begin{cases} h_i(x) \leq 0 & (1 \leq i \leq \ell), \\ r_j(x) = 0 & (1 \leq j \leq m). \end{cases}$$

- Lagrange 双対関数

$$g(\lambda, \nu) := \min_{x \in D} L(x; \lambda, \nu) \quad \lambda \geq 0, \nu \in \mathbf{R}^m$$

where

$$L(x; \lambda, \nu) := f(x) + \sum_{i=1}^{\ell} \lambda_i h_i(x) + \sum_{j=1}^m \nu_j r_j(x).$$

λ, ν は Lagrange 乗数 と呼ばれる.

- Fact: $g(\lambda, \nu)$ は凹関数である.

– 双対問題

$$\max g(\lambda, \nu) \quad \text{subj. to } \lambda \geq 0.$$

- 最適化(特に凸最適化)では, 双対問題を考えると便利ことが多い.

定理4. 1 (弱双対性)

p_* : 主問題の最適値 (infimum)

d_* : 双対問題の最適値 (supremum)

このとき,

$$d_* \leq p_*.$$

∴) For $x \in D$, $\lambda \geq 0$,

$$L(x; \lambda, \nu) = f(x) + \sum_{i=1}^{\ell} \lambda_i h_i(x) + \sum_{j=1}^m \nu_j r_j(x) \leq f(x)$$

Take infimum $\Rightarrow g(\lambda, \nu) \leq p_*$.

強双対性

– 凸最適化問題

- 目的関数 f と不等式制約 h_i が凸関数.
- 等式制約 r_j が線形関数.

– 十分条件: Slater条件

「ある $\tilde{x} \in \text{relint}D$ があって, $h_i(\tilde{x}) < 0$ かつ $r_j(\tilde{x}) = 0$ 」

定理4.2 (強双対性)

主問題が凸最適化問題で, Slater条件を満たすとき, ある

$\lambda_* \geq 0, v_* \in \mathbf{R}^m$ があって,

$$d_* = g(\lambda_*, v_*) = p_*.$$

証明は, 福水B.3, または Boyd 2004 を見よ.

* $\text{relint}D$ (相対的内点): D を含む最小のアフィン部分空間の相対位相としての内点.

相補性条件

(凸とは限らない) 主問題

$$\min_x f(x) \quad \text{subject to} \quad \begin{cases} h_i(x) \leq 0 & (1 \leq i \leq \ell) \\ r_j(x) = 0 & (1 \leq j \leq m) \end{cases}$$

仮定:

x_* : 主問題の解, λ_*, v_* : 双対問題の解 ($\lambda_* \geq 0$)

強双対性を仮定: $f(x_*) = g(\lambda_*, v_*)$.

このとき

$$\begin{aligned} f(x_*) = g(\lambda_*, v_*) &= \inf_x L(x; \lambda_*, v_*) \\ &\leq L(x_*; \lambda_*, v_*) \\ &= f(x_*) + \lambda_*^T h(x_*) + v_*^T r(x_*) \\ &\leq f(x_*) \quad \leq 0 \quad = 0 \end{aligned}$$

2つの不等号は実は等号

– Fact 1:

$$f(x_*) = \inf_x L(x; \lambda_*, \nu_*)$$

主問題の解は, Lagrange関数(最適な λ_*, ν_* のもと)の最適解

– Fact 2:

$$\lambda_{*i} h_i(x_*) = 0 \quad \forall i$$

[相補性条件]

Complementary slackness

$h_i(x_*) < 0$ ならば $\lambda_{*i} = 0$

$\lambda_{*i} > 0$ ならば $h_i(x_*) = 0$.

KKT条件

– 凸最適化. D が開集合. 主問題の目的関数 $f(x)$, 不等式制約 $h_i(x)$ が微分可能とする.

– x_* : 主問題の解

λ_*, v_* : 双対問題の解 ($\lambda_* \geq 0$)

強双対性を仮定

– Lagrange双対: $x_* = \min_x L(x; \lambda_*, v_*)$

微分可能関数の最小化問題として以下を満たす.

$$\nabla f(x_*) + \sum_{i=1}^{\ell} \lambda_{*i} \nabla h_i(x_*) + \sum_{j=1}^m v_{*j} \nabla r_j(x_*) = 0.$$

定理4. 3 (KKT条件)

微分可能な目的関数, 不等式制約からなる凸最適化問題において, 強双対性が成り立つとする. x_* が主問題の解, λ_*, v_* が双対問題の解となるための必要十分条件は, これらが以下のKKT条件を満たすことである.

- (1) $h_i(x) \leq 0 \quad (1 \leq i \leq \ell)$ [主問題の制約]
- (2) $r_j(x) = 0 \quad (1 \leq j \leq m)$ [主問題の制約]
- (3) $\lambda_* \geq 0$ [双対問題の制約]
- (4) $\lambda_{*i} h_i(x_*) = 0 \quad \forall i$ [相補性条件]
- (5) $\nabla f(x_*) + \sum_{i=1}^{\ell} \lambda_{*i} \nabla h_i(x_*) + \sum_{j=1}^m v_{*j} \nabla r_j(x_*) = 0$

証明は, 福水B.3, またはBoyd 2004

– 相補性条件は強双対性から導かれる.

サポートベクターマシンの最適化

SVMの最適化問題(復習)

$(X_1, Y_1), \dots, (X_n, Y_n)$: 2値分類問題 $Y_i \in \{+1, -1\}$.

– SVMの最適化問題(QP): 主問題

$$\min_{w, b, \xi} \sum_i w_i w_j K_{ij} + C \sum_i \xi_i$$

$$\text{subj. to } Y_i (\sum_j w_j K_{ij} + b) \geq 1 - \xi_i$$

$$\xi_i \geq 0.$$

$$K_{ij} = k(X_i, X_j)$$

$$f(x) = h(x) + b = \sum_{j=1}^n w_j k(x, X_j) + b$$

SVMの双対問題

■ SVMの双対問題

$$\max_{\alpha} \sum_{i=1}^n \alpha_i - \sum_{i,j=1}^n \alpha_i \alpha_j Y_i Y_j K_{ij}$$

subject to $0 \leq \alpha_i \leq C,$
 $\sum_{i=1}^n Y_i \alpha_i = 0$

[演習問題] Lagrange双対を書き下すことによって, 上の形を導け.

- 双対問題もQP.
- 制約は主問題より簡単(区間制約と1個の等式制約)
双対問題を解くことが多い.

SVMのKKT条件

■ SVMのKKT条件

- (1) $1 - Y_i (h^*(X_i) + b^*) - \xi_i^* \leq 0 \ (\forall i)$ [primal constraint]
- (2) $\xi_i^* \geq 0 \ (\forall i)$ [primal constraint]
- (3) $0 \leq \alpha_i^* \leq C, \ (\forall i)$ [dual constraint]
- (4) $\alpha_i^* (1 - Y_i (h^*(X_i) + b^*) - \xi_i^*) = 0 \ (\forall i)$ [complementary]
- (5) $\xi_i^* (C - \alpha_i^*) = 0 \ (\forall i),$ [complementary]
- (6) $\sum_{j=1}^n K_{ij} w_j^* - \sum_j \alpha_j^* Y_j K_{ij} = 0,$
- (7) $\sum_{j=1}^n \alpha_j^* Y_j = 0,$


- SVMの解: (6)の条件より, $w_j^* = Y_j \alpha_j^*$.
- (4)の相補性条件より, $\alpha_i^* \neq 0$ となるのは, $Y_i (h^*(X_i) + b^*) = 1 - \xi_i^*$ の場合に限られる.

サポートベクター

■ SVMの解のスパース性

$$f_*(x) = h_*(x) + b_* = \sum_{X_i: \text{support vectors}} \alpha_{i*} Y_i K(x, X_i) + b_*$$

- サポートベクター ($\alpha_i^* \neq 0$ なるもの)には2種類ある(条件(5)参照).



b の求め方

- 最適な b は条件(4)により求められる.

$0 < \alpha_i^* < C$ なる i に対して,

$$Y_i (\sum_j Y_j \alpha_j^* k(X_i, X_j) + b^*) = 1$$

を解く.

- または, 上のすべての i に対する b を平均する.

SVMの解法いろいろ

実際には, 大規模な問題には標準的QPソルバーは困難

- SMO (Sequential Minimal Optimization)
2変数の最適化を繰り返す. (Platt 1999)
- 主問題を解く
- オンライン学習
- 並列アルゴリズム

などなど.

多クラス識別への拡張

■ マージン最大化規準の多クラスへの拡張

■ 2値識別器の組み合わせ

- One-vs-rest: 各クラスとその他
- One-vs-one: すべてのペア
- ECOC (Error correcting output code) 符号化する

class	f_1	f_2	f_3	f_4	f_5	f_6
C_1	-1	-1	-1	1	1	1
C_2	-1	1	1	-1	-1	1
C_3	1	-1	1	-1	1	-1
C_4	1	1	-1	-1	1	1

汎化誤差

SVMに関しては、Vapnikらが発展させた「統計的学習理論」の枠組みで、マージンなどを用いた汎化誤差に関する理論研究が多く行われている。

ただし、本講義では扱わないので、福水5章、Cristianini & Shawe-Taylor (2000) などを見ていただきたい。

References

福水 「カーネル法入門」 4章 朝倉書店 2010

Schölkopf, B., A.J. Smola. *Learning with Kernels*. MIT Press 2001

Cristianini, N., J. Shawe-Taylor. *An Introduction to Support Vector Machines*.
Cambridge Univ. Press. 2000

Platt, J. Fast training of support vector machines using sequential minimal optimization. In
B. Schölkopf, C. Burges, and A. Smola, editors, *Advances in Kernel Methods -
Support Vector Learning*, pages 185–208. MIT Press, 1999.

Boyd S. and L. Vandenberghe. *Convex Optimization*. Cambridge University Press, 2004.
<http://www.stanford.edu/boyd/cvxbook/>.

– Books on Application domains:

Lee, S.-W., A. Verri (Eds.) *Pattern Recognition with Support Vector Machines: First
International Workshop, SVM 2002, Niagara Falls, Canada, August 10, 2002*.
Proceedings. Lecture Notes in Computer Science 2388, Springer, 2002.

Joachims, T. *Learning to Classify Text Using Support Vector Machines: Methods,
Theory and Algorithms*. Springer, 2002.

Schölkopf, B., K. Tsuda, J.-P. Vert (Eds.). *Kernel Methods in Computational Biology*.
MIT Press, 2004.