

不確実性下での最適化手法： ロバスト最適化法の紹介

数理最適化分野でのロバストネス

東京大学・理研 武田朗子

概要

- **ロバスト最適化法**
 - ✓ 概要（考え方、歴史的経緯）
 - ✓ ロバスト最適化問題の解き方
 - ✓ 機械学習分野の判別モデルにおけるロバスト性

不確実性を考慮した最適化法

最適化問題:

$$\min_{\boldsymbol{x}} f(\boldsymbol{x})$$

$$\text{s.t. } g_i(\boldsymbol{x}) \leq 0, \quad i = 1, \dots, m$$

●確率計画法

- ✓ 古くから(1950年代より)研究あり
- ✓ 確率分布を仮定して, リスク尺度を用いたモデル化

●ロバスト最適化法

- ✓ 1998年にBen-Tal & Nemirovskiによって提案
- ✓ 不確実なデータの取りうる範囲を仮定して, 最悪状況で最適な意思決定をするようなモデル化

ロバスト最適化法の基礎と使い方について紹介

ロバスト最適化法とは？

Ben-Tal & Nemirovski ['98]

不確実性を含んだ最適化問題のモデル化とその解法

目的： どんな状況が起こっても大きな損害を被らないよう、意思決定をしたい

● 電力供給コスト最小にするための生産量は？

$$\begin{array}{ll} \min_{\mathbf{x} \geq \mathbf{0}} & \sum_{i=1}^3 u_i x_i \\ \text{s.t.} & \sum_{i=1}^3 x_i \geq d \end{array}$$

3 基の発電機
(燃料：石油, 石炭, ガス)
 x_i : 生産量
 u_i : 単位コスト, d : 需要量

不確実性大

ロバスト最適化問題

不確実なデータの範囲をあらかじめ設定した上で、
最悪事態の発生を想定して最適化を行なう問題

不確実なデータの範囲を設定: $u \in \mathcal{U}, d \in [d_\ell, d_u]$

$$\begin{array}{l} \min_{x \geq 0} \sum_{i=1}^3 u_i x_i \\ \text{s.t.} \quad \sum_{i=1}^3 x_i \geq d \end{array} \quad \Rightarrow \quad \min_x \max_{u \in \mathcal{U}} \sum_{i=1}^3 u_i x_i$$
$$\sum_{i=1}^3 x_i \geq d, \quad \forall d \in [d_\ell, d_u]$$
$$\Leftrightarrow \sum_{i=1}^3 x_i \geq \max_{d \in [d_\ell, d_u]} d$$

データの不現実性を考えることの大切さ

Ben-Tal & Nemirovski ['00]

PILOT4 (NETLIB library)

1000変数、410制約式、最適解を x^* とする

$$a^\top x \equiv$$

$$\begin{aligned} & -15.79081x_{826} - 8.598819x_{827} - 1.88789x_{828} - 1.362417 \dots \\ & -0.031883x_{849} - 28.725555x_{850} - 10.792065x_{851} - 0.190 \dots \\ & -12.290832x_{854} + 717.562256x_{855} - 0.057865x_{856} - 3.785 \\ & -122.163055x_{859} - 6.46609x_{860} - 0.48371x_{861} - 0.615264 \dots \\ & -84.644257x_{864} - 122.459045x_{865} - 43.15593x_{866} - 1.712 \dots \\ & +x_{880} - 0.946049x_{898} - 0.946049x_{916} \geq \boxed{23.387405} \equiv b \end{aligned}$$

実数値係数を0.1%ずらす $\rightarrow \bar{a}$

たとえば、 $15.79081 \times 0.001 = 0.0157908$

$a^\top x^* - b \geq 0$ を満たす解 x^* で、摂動を加えた式を評価:
 $\bar{a}^\top x^* - b < -104.9$ (大きく制約式を破る)

ロバスト最適化法の適用例 -1-

ロバスト性を考慮した建築構造設計: 寒野 [’08]

建築構造物は外力に対し、不安定現象を生じないように設計の必要あり

- 構造物に作用する外力を、正確に予測することは難しい
- 構造物の解析・設計において、外力のばらつきを考慮

ロバスト化学プロセス設計 Lin, Janak & Floudas [’04]

化学プロセスは反応器、蒸留塔などの単位操作の組み合わせで、原材料から目的物質を製造

- 環境影響(外因)による安全性への影響を考慮して、経済性最大化を達成する必要あり

ロボスト最適化法の適用例 -2-

土谷 & 笹川 [’05]

超電導磁気浮上式列車の磁気シールド最適設計:

車体を強磁性体のシールドで覆い、車内を強力な磁場から遮蔽する必要あり

→車内へ磁場が漏洩しない条件下でシールド重量最小化

→“近似計算”による外部磁場の不確実性を考慮

ロボスト最短路問題(離散最適化):

Yu & Yang [’98]

渋滞等による所要時間の不確実性を考慮した最短路問題

クラス分類モデル (機械学習):

観測値に観測誤差が含まれることを想定した手法

ポートフォリオ選択 (金融工学):

株価の不確実性を考慮して、最適資産配分を決定

放射線治療への適用


癌患者のための放射線治療

Chan, Bortfeld & Tsitsiklis ['06]

放射線をいろいろな角度から照射する際に、

* 腫瘍に重なるようにする

* 周辺の重要な臓器を避けるようにする



→ 放射線ビームの角度と強度などを最適化法で決定

→ **腫瘍の位置の不確実性を考慮**

(例えば、治療中に患者が呼吸することで、肺腫瘍の位置が動く)

他手法との関係 (vs. 確率計画)

不確実な最適化問題:

$$\min_{x \in X} f(x, u_0) \text{ s.t. } g(x, u_1) \leq 0$$

u_0, u_1
不確実なデータ

● 確率計画法


仮定: u_0, u_1 の確率分布が既知

$$\min_{x \in X} E_{u_0}[f(x, u_0)]$$

$$\text{s.t. } \Pr_{u_1}\{g(x, u_1) \leq 0\} \geq 1 - \epsilon$$

機会制約 (確率制約) Charnes & Cooper ['59]

Dantzig, Beale ['55]



Cf.) ロバスト最適化法

仮定: u の属する領域 \mathcal{U} が既知

$$\min_{x \in X} \max_{u \in \mathcal{U}} f(x, u)$$

最適化分野でのロバスト最適化法の歴史

ロバスト最適化法

u の属する領域 \mathcal{U} が既知

$$\min_{x \in X} \max_{u \in \mathcal{U}} f(x, u)$$


■ 1973年 A.L. Soyster が 矩形の \mathcal{U}

(手法は inexact LP と呼ばれ、解は “保守的すぎる”)




この間、進展なし (論文2本†)

†) reported by Ben-Tal, El Ghaoui & Nemirovski [’09]



■ 1998年 Ben-Tal & Nemirovski が 楕円形

El Ghaoui & Lebret, Kouvelis & Yu も同時期
に同様の定式化



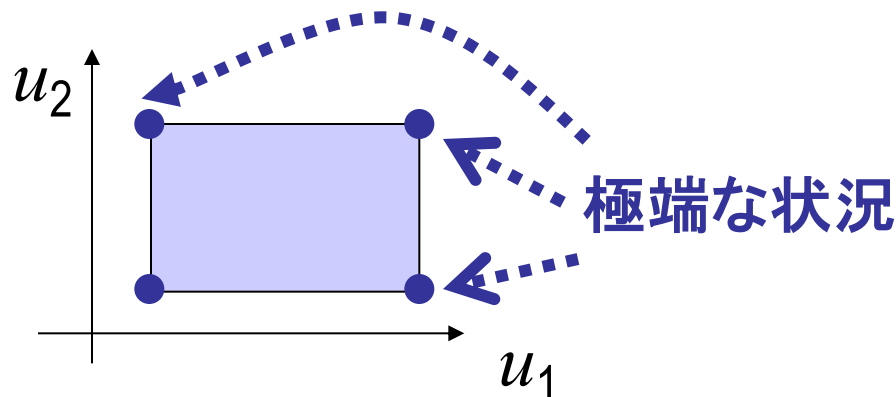
■ 続々と、研究つづく

ロバスト最適化がうけた理由

- ① 矩形だと、極端な状況を想定するだけ。
この欠点が解消された。
- ② 二次錐計画や半正定値計画に帰着
(➡ 内点法で解ける)。


inexact LP
Soyster ['73]

U が矩形

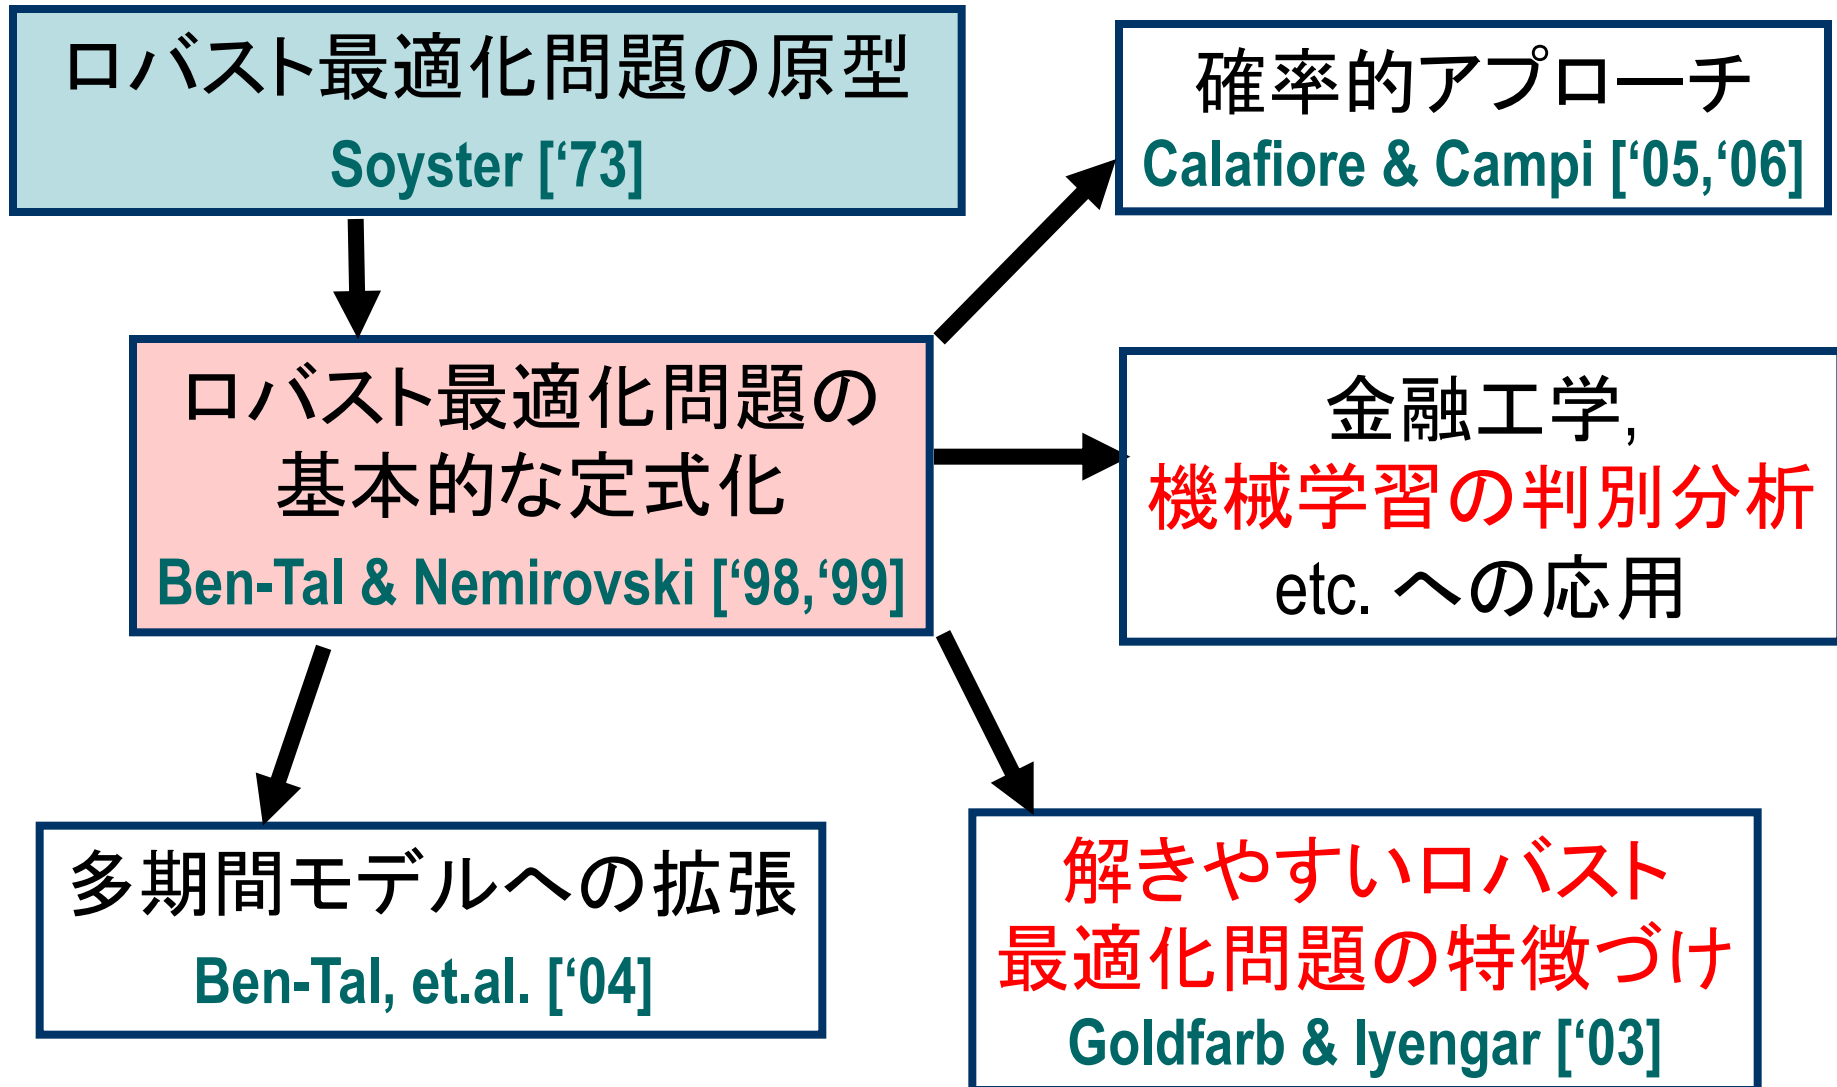


ロバストLP
Ben-Tal & Nemirovski ['98]

U が楕円 etc..



ロバスト最適化研究の様々な流れ



概要

- **ロバスト最適化法**
 - ✓ 概要（考え方、歴史的経緯）
 - ✓ **ロバスト最適化問題の解き方**
 - ✓ 機械学習分野の判別モデルにおけるロバスト性

ロバスト最適化問題のイメージ

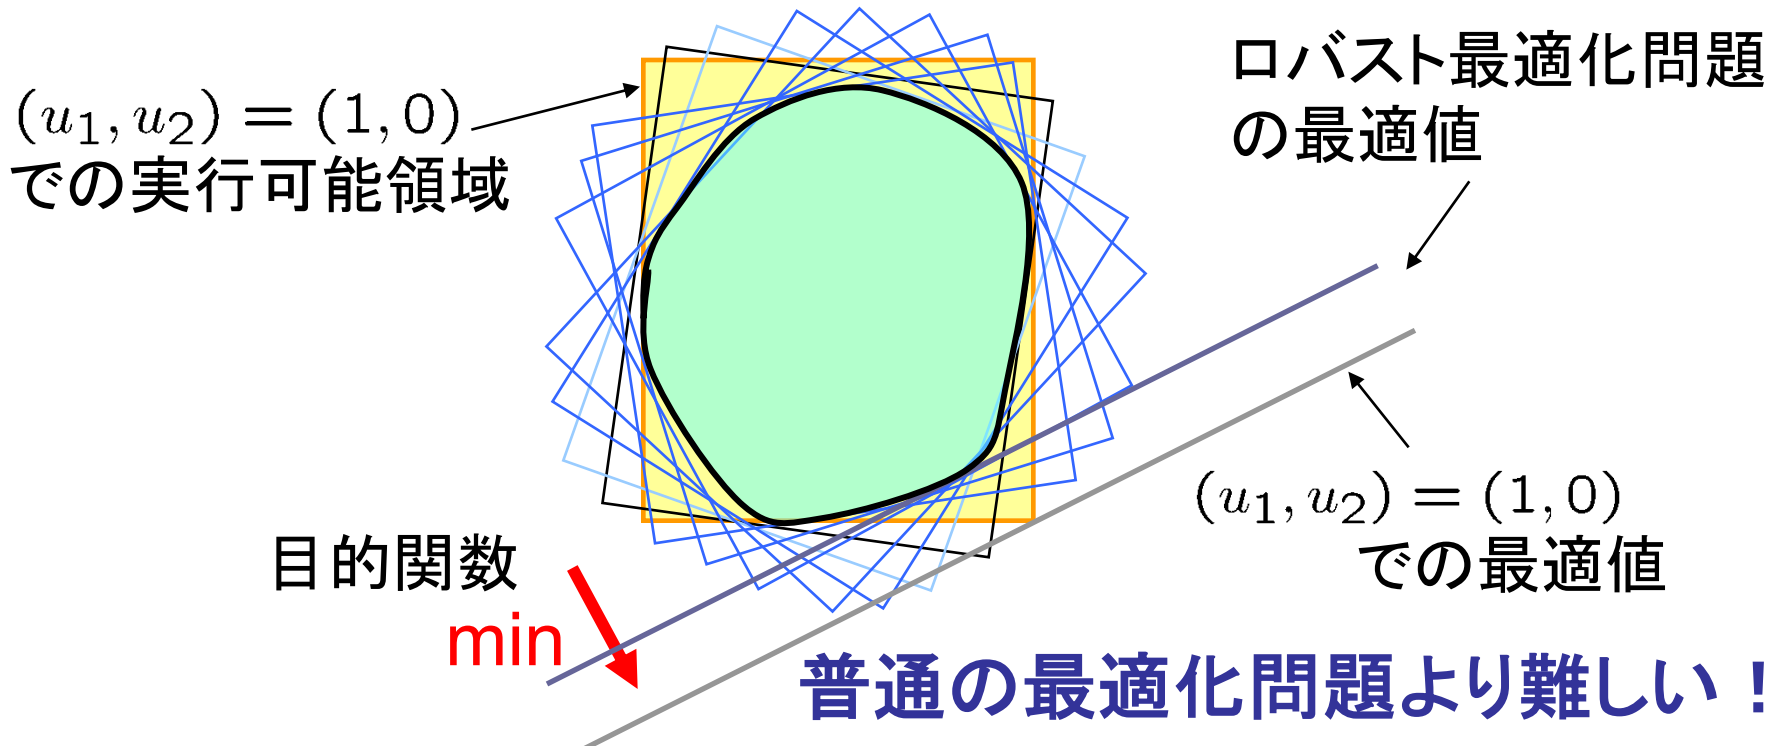
$$\min_x -x_1 + x_2$$

$$\text{s.t.} \quad -1 \leq u_1 x_1 + u_2 x_2 \leq 1$$

$$-1 \leq -u_2 x_1 + u_1 x_2 \leq 1$$

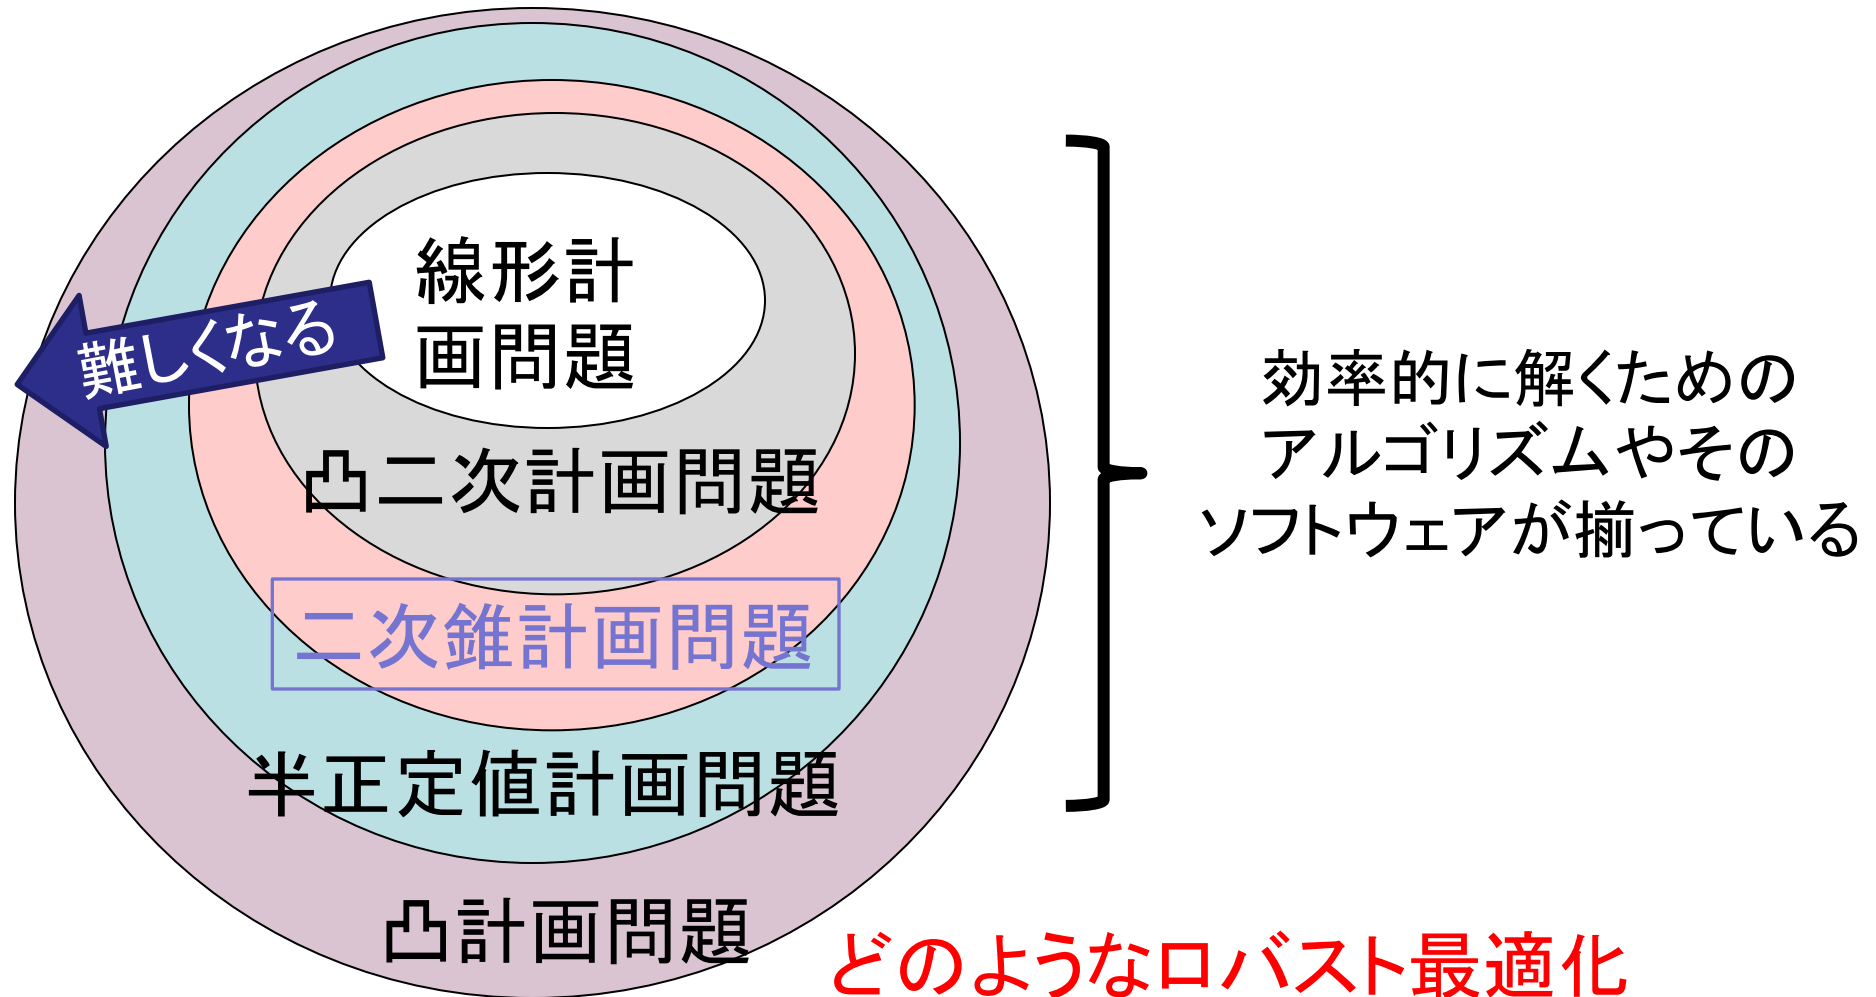
$$\forall u \in \mathcal{U} = \{(u_1, u_2) \mid u_1^2 + u_2^2 = 1\}$$

制約式は無制限本



代表的な最適化問題

連続最適化



どのようなロバスト最適化問題が、これらに帰着できるか？

ロバスト最適化問題の標準形

$$\min_{\mathbf{x} \in X} \mathbf{c}^\top \mathbf{x} \quad \text{s.t.} \quad f_i(\mathbf{x}, \mathbf{u}_i) \leq 0, \quad \forall \mathbf{u}_i \in \mathcal{U}_i, \\ i = 1, \dots, m$$

制約毎の不確実性 (constraint-wise uncertainty)

$$f_i(\mathbf{x}, \mathbf{u}_i) : \mathbf{u}_i \text{ について凸} \quad (\forall \mathbf{u}_i \in \mathcal{U}_i)$$

X : 閉凸集合, \mathcal{U}_i : 有界閉集合

- 目的関数の不確実なとき

$$\min_{\mathbf{x} \in X} \max_{\mathbf{u}_0 \in \mathcal{U}_0} f_0(\mathbf{x}, \mathbf{u}_0)$$

$$\longrightarrow \min_{\mathbf{x} \in X, t} t \quad \text{s.t.} \quad f_0(\mathbf{x}, \mathbf{u}_0) \leq t, \quad \forall \mathbf{u}_0 \in \mathcal{U}_0$$


ロバストLP (楕円型不確実性集合)

Ben-Tal & Nemirovski [‘99]

$$\min_x c^\top x \quad \text{s.t.} \quad a^\top x \leq b, \quad \forall a \in \mathcal{U}$$

楕円型:

$$\mathcal{U} = \{a_0 + Au : \|u\|_2 \leq 1\}$$



$$\min_x c^\top x \quad \text{s.t.} \quad a_0^\top x + x^\top Au \leq b, \quad \|u\|_2 \leq 1,$$

↓

$$a_0^\top x + \left(\max_{u: \|u\|_2 \leq 1} x^\top Au \right) \leq b$$

$$u^* = \frac{A^\top x}{\|A^\top x\|_2}$$

$$\min_x c^\top x \quad \text{s.t.} \quad a_0^\top x + \|A^\top x\|_2 \leq b$$

二次錐計画問題

ロバスト最適化問題は解ける！？

$$\min_{x \in X} c^\top x \quad \text{s.t.} \quad f_i(x, u_i) \leq 0, \quad \forall u_i \in \mathcal{U}_i, \\ i = 1, \dots, m$$

→ 解きやすい凸計画問題に変形するためには

Ben-Tal & Nemirovski ['98], Goldfarb & Iyengar ['03]

3つの仮定

(1) $f(x, u)$ は x について凸二次



$$f(x, u) = x^\top Q(u)x + q(u)^\top x + \gamma(u)$$

(2) 不確定データは u について線形

$$Q(u) = Q_0 + \sum_i Q_i u_i$$

$$q(u) = q_0 + \sum_i q_i u_i$$

(3) \mathcal{U}_i は有限集合、その凸包、もしくは楕円



ロバスト最適化の定式化のコツ

ロバスト最適化では.....

✓不確実データの表現方法がポイント！

✓その表現方法に制限が大きい

•不確実データは u について線形、

• u は楕円内を動く, etc.

✓その制限を満たせば、扱いやすい問題に変換できる

- どういう問題構造をしていけば扱いやすい問題に変換できる？
- 条件を満たさない場合は、無限本制約をすべて考慮するのでなく、うまくサンプリングすることによる確率的解法

概要

- **ロバスト最適化法**
 - ✓ 概要（考え方、歴史的経緯）
 - ✓ ロバスト最適化問題の解き方
 - ✓ 機械学習分野の判別モデルにおけるロバスト性

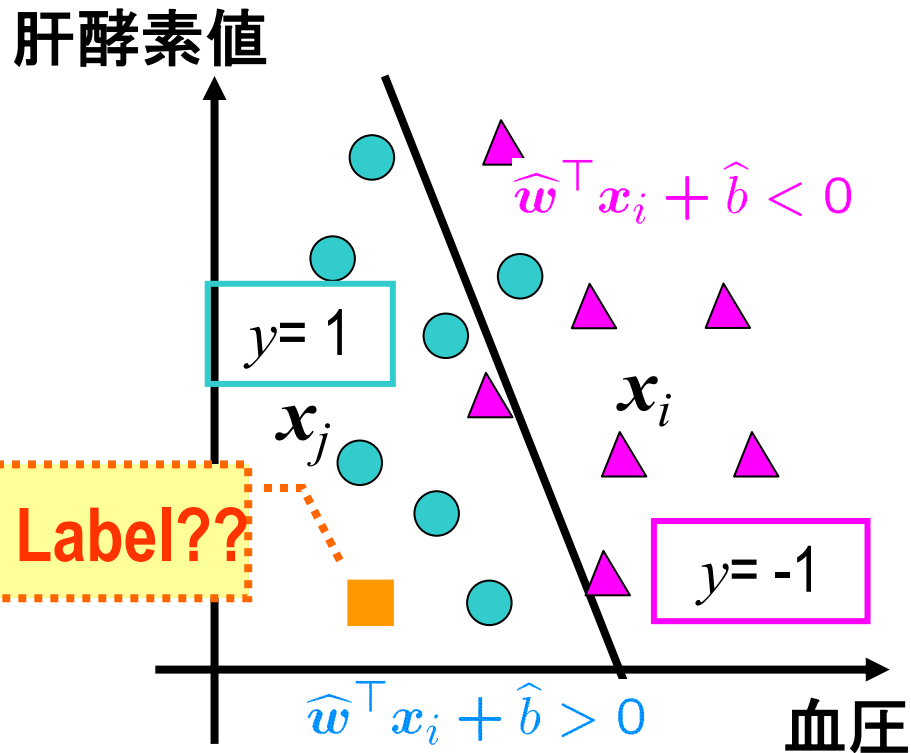
肝臓疾患の判別

特徴ベクトル

$x_i =$ { 赤血球の濃さ
.....
肝酵素値
一日の飲酒量 }

$y_i =$ { 1 健康
-1 肝臓疾患 }

$i = 1, \dots, m$



➔ $h(x) = \text{sign}(w^T x + b)$

線形判別関数を扱うがカーネル法により非線形関数に拡張可能

学習に用いなかった未知のデータ x のラベル y をうまく予測したい

SVM(サポートベクトルマシン) におけるロバスト性


所与のデータに過適合(オーバーフィット)
しない判別関数を求めるために正則化

定式化は同値

Xu, Caramanis & Mannor ['09]


所与のデータの微小変動に
対して頑健な解を求めるために
ロバスト化

判別分析における「ロバスト性」は
「正則化」によって考慮されている



ソフトマージンSVM (線形分離不可能な場合)

Cortes & Vapnik ['95]



$$\begin{aligned} \min_{w, b, z} \quad & \delta \|w\| + \sum_{i=1}^m z_i \\ \text{s.t.} \quad & y_i (w^T x_i + b) \geq 1 - z_i, \\ & z_i \geq 0, \quad i = 1, \dots, m \end{aligned}$$

δ は2つの目的をコントロール


- 損失最小 ($\min \sum_{i=1}^m z_i$)
- マージン最大化 ($\max \frac{1}{\|w\|}$)

この目的を加えることを**正則化**
(過適合を防ぐ役割)

正則化＝ロバスト化

正則化

$$\begin{aligned} \min_{\mathbf{w}, b, \mathbf{z}} \quad & \delta \|\mathbf{w}\| + \sum_{i=1}^m z_i \\ \text{s.t.} \quad & y_i (\mathbf{w}^\top \mathbf{x}_i^o + b) \geq 1 - z_i, \\ & z_i \geq 0, \quad i = 1, \dots, m \end{aligned}$$



同値

正則化項を除く

$$\min_{\mathbf{w}, b} \sum_{i=1}^m [1 - y_i (\mathbf{w}^\top \mathbf{x}_i^o + b)]^+$$

$$[a]^+ := \max\{a, 0\}$$

ロバスト化

Xu, Caramanis & Mannor ['09]

$$\begin{aligned} \min_{\mathbf{w}, b} \max_{(\Delta \mathbf{x}_1, \dots, \Delta \mathbf{x}_m) \in \mathcal{U}} \quad & \sum_{i=1}^m [1 - y_i \{\mathbf{w}^\top (\mathbf{x}_i^o + \Delta \mathbf{x}_i) + b\}]^+ \\ \mathcal{U} = \quad & \{(\Delta \mathbf{x}_1, \dots, \Delta \mathbf{x}_m) : \sum_{i=1}^m \|\Delta \mathbf{x}_i\| \leq \delta\} \end{aligned}$$

敵対的擾動 (adversarial example)

画像に擾動を与えることにより誤分類してしまう

擾動に強い判別モデル

$$\min_{w,b} \max_{\delta \in \mathcal{U}} r(w) + \sum_{i=1}^m J(w, b; \mathbf{x}_i + \delta_i, y_i)$$

x

“panda”

57.7% confidence

$\text{sign}(\nabla_x J(\theta, x, y))$

“nematode”

8.2% confidence

$x + \epsilon \text{sign}(\nabla_x J(\theta, x, y))$

“gibbon”

99.3 % confidence

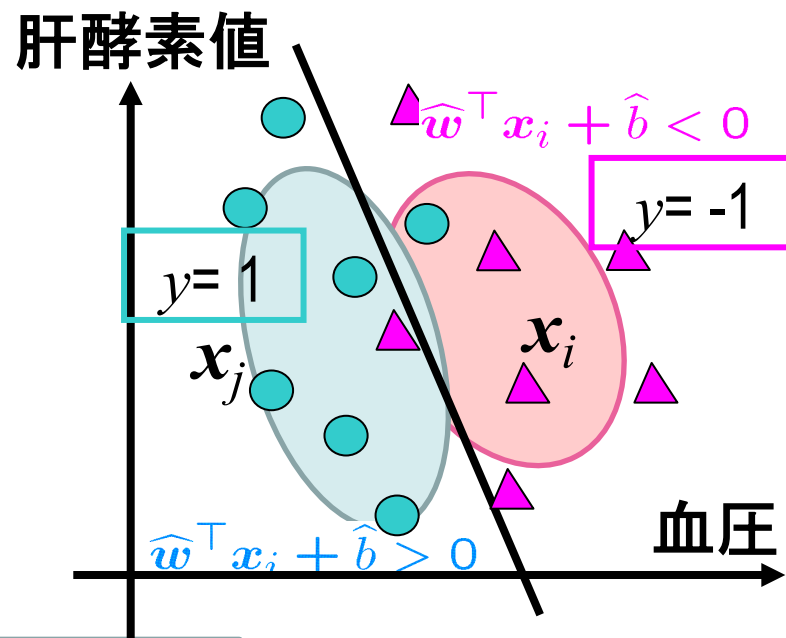
判別モデル: $\min_{w,b} r(w) + \sum_{i=1}^m J(w, b; \mathbf{x}_i, y_i)$

目的関数値が増大する勾配

ロバスト最適化による 判別モデルの解釈

Takeda, Mitsugi & Kanamori
(ICML ['12], Neural Computation ['13])

ロバスト最適化法による,
観測データに頑健な判別モデル



$$\max_{\|w\|=1} \min_{x_+ \in \mathcal{U}_+, x_- \in \mathcal{U}_-} (x_+ - x_-)^T w$$

$$\Rightarrow f(x) = w^{*\top} x + b^*$$

- ✓ x_+, x_- : 各クラスの平均ベクトル (真の分布が未知なので不確定)
- ✓ $\mathcal{U}_+, \mathcal{U}_-$: 有界閉凸な不確実性集合 (x_+, x_- の動きうる範囲)
- ✓ b は x_+^* と x_-^* の真ん中を通るように計算される


不確実性集合の例

U_+ と U_- は各クラスのデータ集合より構築される

← パラメータ κ によって大きさコントロール

パラメータ: $\kappa = \frac{2}{\nu m}$

- $\nu=0.0$
- - $\nu=0.2$
- - - $\nu=0.4$
- $\nu=0.6$
- - - $\nu=0.8$



縮退凸包 (reduced convex hull)


Bennett & Bredensteiner ['00], Crisp & Burges ['00]

$$U_+ = \left\{ \sum_{i \in M_+} \lambda_i \mathbf{x}_i : \mathbf{e}^\top \boldsymbol{\lambda} = 1, \mathbf{0} \leq \boldsymbol{\lambda} \leq \kappa \mathbf{e} \right\}$$

楕円2:



$$U_+ = \left\{ \bar{\mathbf{x}}_+ + \Sigma_+^{1/2} \mathbf{u} : \|\mathbf{u}\| \leq \kappa \right\}$$

訓練データの平均: $\bar{\mathbf{x}}_+$, $\bar{\mathbf{x}}_-$
 分散共分散行列: Σ_+ , Σ_-




既存モデルとの関係

u_+, u_-	交わりあり	接する	交わりなし
楕円1 :	なし	Fisher Discriminant Analysis (FDA) Fukunaga ('90)	Sparse Feature Selection Bhattacharyya ('04)
楕円2 :	なし	Minimax Probability Machine (MPM) Lanckriet et al. ('02)	Minimum Margin-MPM Nath & Bhattacharyya ('07)
縮退凸包 :	E _v -SVM Perez-Cruz et al. ('03)	ν-SVM (= Soft Margin SVM) Scholkopf et al. ('00)	
凸包 :		-----	Hard Margin SVM Boser et al. ('92)




凸計画



他に, L2-SVM, ロジスティック回帰なども...

既存モデルとの関係

u_+, u_-	交わりあり	接する	交わりなし
楕円1 :	モデル提案 (非凸2次最適化)	Fisher Discriminant Analysis (FDA) Fukunaga ('90)	Sparse Feature Selection Bhattacharyya ('04)
楕円2 :	モデル提案 (非凸2次最適化)	Minimax Probability Machine (MPM) Lanckriet et al. ('02)	Minimum Margin-MPM Nath & Bhattacharyya ('07)
縮退凸包 :	E _v -SVM Perez-Cruz et al. ('03)	ν-SVM (= Soft Margin SVM) Scholkopf et al. ('00)	
凸包 :		-----	Hard Margin SVM Boser et al. ('92)



一般的な非凸2次最適化問題の解法提案
(AISTATS'14, SIOPT'15,'16)

凸計画
一次最適化法による
統一的な解法の提案
(JMLR'17)

まとめ

- 現代社会は変化のスピードが速く、不確実性への対応は必須
- min-maxの定式化は機械学習分野で活発な研究対象 (e.g., adversarial attack)
- ロバスト最適化は比較的新しい分野
Ben-Tal, El Ghaoui & Nemirovski [’09]
- 分野を超えてロバスト最適化研究が広がっている
 - ✓ 上記の本の冒頭で
ロバスト制御 (H_∞ 制御)、ロバスト統計、機械学習 (SVM) などについて言及あり
- 機械学習分野でもロバスト最適化が使われている