

ランキングSVMを用いた コンピュータ将棋における 評価関数の学習

九州大学大学院システム情報科学府
修士2年 末廣 大貴

京都と将棋

京都将棋



京都将棋

- * 1976年，田宮克哉氏が発表
- * 京都銀閣将棋，京都銀閣金鷄秘譜将棋とも
- * 盤面は縦横5マス
- * 大山康晴十五世名人が絶賛？

(Wikipedia より)

5	4	3	2	1	
飛	角	銀	金	王	一
				歩	二
					三
歩					四
玉	金	銀	角	飛	五

参考：5五将棋

京都将棋

ルール

- 自陣, 敵陣はない
- 香車の裏はと金
- 銀将の裏は角将
- 金将の裏は桂馬
- 飛車の裏は歩兵
- 一手動かすごとに駒を裏返す
- 取った駒は表裏どっちで打ってもよい

5	4	3	2	1	
香	銀	王	飛	香	一
					二
					三
					四
と	銀	玉	金	歩	五

初期配置

目次

- * コンピュータ将棋の歴史と研究背景
- * 評価関数
- * SVM と多項式カーネル
- * ランキング SVM
- * 実験
- * まとめと今後の課題

コンピュータ将棋の歴史

1974年 コンピュータ将棋開発開始？

～ 探索と評価関数の試行錯誤 ～


2005年 「激指」がアマ竜王戦でベスト16

2006年 「Bonanza」の登場

～ 評価関数の自動調整化～


2010年 「あから2010」が清水市代女流王将
(当時) に勝利

STR 誕生



STR

- * 第20回世界コンピュータ将棋選手権で世界デビュー？
- * 現在世界最弱と思われる
- * 序盤はたまにまともな将棋を指す
- * イメージキャラクターはやる夫



背景

* 強いコンピュータ将棋ソフトを作るには

* 探索アルゴリズム

* 評価関数

* 高速化

背景

* 強いコンピュータ将棋ソフトを作るには

* 探索アルゴリズム

* 評価関数

* 高速化

評価関数 f

入力：局面の特徴を表現するベクトル x

出力：実数（評価値）

w を特徴の重みベクトルとしたとき、

$$f(x) = w \cdot x$$

特徴

将棋において重要そうな（？）ものを用意

- * 駒の価値
- * 玉に対する金，銀の位置
- * 玉の危険度（玉周辺の駒の利き）
- * 各駒の働き
 - * 駒同士の位置関係
 - * 駒が動けるか
 - * 利きの数
 - * ひもがついているか
- などなど・・・

評価関数の作り方

	従来	近年	提案手法	
特徴	作成者が用意	作成者が用意	自動生成	→ 多項式カーネル
重み	手作業で調整	自動調整	自動調整	→ SVM



Bonanza Method [保木 '09] など

機械学習の分野ではかなり一般的な手法であり、基礎データをとる意味でもやってみる価値はある



SVMと多項式カーネル

SVM (サポートベクトルマシン)

- * 2値クラス分類に用いられる線形学習システム
- * マージン最大化の原理に基づいて重みを求める
 - ➡ 分類精度が高いことが保証されている

サンプル集合

$$(\boldsymbol{x}_1, y_1), \dots, (\boldsymbol{x}_m, y_m)$$

$$\boldsymbol{x}_i \in \mathbb{R}^n, y_i \in \{1, -1\}$$

$$\begin{bmatrix} \boldsymbol{x}_1 \cdot \boldsymbol{x}_1 & \cdots & \boldsymbol{x}_1 \cdot \boldsymbol{x}_m \\ \vdots & \ddots & \vdots \\ \boldsymbol{x}_m \cdot \boldsymbol{x}_1 & \cdots & \boldsymbol{x}_m \cdot \boldsymbol{x}_m \end{bmatrix}$$

マージン最大化

未知の例 \boldsymbol{z} が与えられる


$$\downarrow f(\boldsymbol{z}) = \boldsymbol{w} \cdot \boldsymbol{z}$$

超平面に応じて (f の符号) 予測

\boldsymbol{w} ゲット


マージン

超平面 \boldsymbol{w}



非線形写像 ϕ による学習精度の向上

$$\phi : \mathbb{R}^n \rightarrow \mathbb{R}^N \quad (N \gg n)$$



カーネルトリック

$$(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_m, y_m)$$

$$\mathbf{w} \in \mathbb{R}^N$$

$$\begin{bmatrix} \phi(\mathbf{x}_1) \cdot \phi(\mathbf{x}_1) & \cdots & \phi(\mathbf{x}_1) \cdot \phi(\mathbf{x}_m) \\ \vdots & \ddots & \vdots \\ \phi(\mathbf{x}_m) \cdot \phi(\mathbf{x}_1) & \cdots & \phi(\mathbf{x}_m) \cdot \phi(\mathbf{x}_m) \end{bmatrix}$$

$$= \sum_i^m \alpha_i \phi(\mathbf{x}_i)$$

$$f(\mathbf{x}) = \mathbf{w} \cdot \phi(\mathbf{x})$$

$$= \sum_i^m \alpha_i K(\mathbf{x}, \mathbf{x}_i)$$

マージン最大化

$$K(\mathbf{a}, \mathbf{b}) = \phi(\mathbf{a}) \cdot \phi(\mathbf{b})$$

カーネル関数

次元が増えているので計算時間が増大しそうだが . . .

特徴写像 ϕ の選択に向けて

このように将棋における複雑な特徴の多くが、局面を表現する基本的で単純な特徴の d 項関係として表現可能な点に着目

基本的で単純な特徴（低次の特徴）

- (1) 盤上にある各駒の数
- (2) 持ち駒の種類とその数
- (3) 盤上の各枡に位置している駒の種類
- (4) 盤上の各枡に対する利きの有無とその駒の種類

(約 4000 次元)

ちなみに 2009 年度世界コンピュータ将棋選手権優勝の GPS 将棋が学習に用いたものは **300万次元**

- * 玉に対する金, 銀の位置 → 玉の位置 \wedge 金銀の位置
- * 玉の危険度 (玉周辺の駒の利き)
 - 玉の位置 \wedge 敵駒の利き \wedge 敵駒の利き \wedge . . .
- * 各駒の働き
 - * 駒同士の位置関係 → 駒の位置 \wedge 駒の位置 \wedge . . .
 - * 駒が動けるか → 駒の利き \wedge 味方の駒の位置
 - * 利きの数 → 駒の利き \wedge 駒の利き \wedge . . .
 - * ひもがついているか → 駒の位置 \wedge 駒の利き

全てではないが, 多くのものは特徴同士の d 項関係で表現可能

ナイーブにやると・・・

例：2次元の高々2項の関係を考慮 $x = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$

$$\phi_{2,2}(x) = (x_1 x_2, x_1, x_2, 1)$$

約
 3×10^{29}
次元！

例：4000次元の高々10項の関係を考慮

$$\phi_{4000,10}(x) = (x_1 x_2 x_3 \cdots, x_2 x_3 x_4 \cdots, \dots)$$


Amedeo Avogadro アボガドロさん

単純に d 項関係を考えると、次元数が膨大になってしまう

多項式カーネル

$$K(\mathbf{a}, \mathbf{b}) = (\mathbf{a} \cdot \mathbf{b} + 1)^d = \phi_{n,d}(\mathbf{a}) \cdot \phi_{n,d}(\mathbf{b})$$

(本研究で用いた多項式カーネル)

対応する特徴空間 \mathbb{R}^N , $N = \binom{n+d}{d}$ の各次元が、

高々 d 次の単項式に対応する ※ n は低次の特徴の次元数

→ 低次の特徴の k 項関係 ($k \leq d$) で、単項式として表すことのできるものを全て特徴として含んでいる

カーネルの計算量は次数 d を上げてもほとんど変わらない ($O(n)$ 時間で計算可能)

学習サンプルの作り方

棋譜データ

ある局面 x

9	8	7	6	5	4	3	2	1	
香	桂			金	銀	桂	香		一
	飛		金	王	角				二
歩		歩	歩	歩	歩	歩	歩		三
		歩	歩	歩					四
	歩								五
		歩	歩						六
歩	歩	角		歩	歩	歩	歩	歩	七
		銀	飛			王			八
香	桂		金	金	銀	桂	香		九

合法手後の局面を作成



$P(x)$

$N(x)$

$P(x)$: x の次局面で棋譜データに現れるものの集合

$N(x)$: x の次局面で棋譜データに現れないものの集合

学習の流れ

$$S = \{(\boldsymbol{x}^+, 1) \mid \boldsymbol{x}^+ \in \bigcup_x P(\boldsymbol{x})\} \cup \{(\boldsymbol{x}^-, -1) \mid \boldsymbol{x}^- \in \bigcup_x N(\boldsymbol{x})\}$$

正例

負例



SVM

特徴写像 ϕ



$$f_{\text{SVM}}(\boldsymbol{x}) = \boldsymbol{w} \cdot \phi(\boldsymbol{x}) \quad (\text{評価関数})$$

棋譜に現れる局面を正例，現れないものを負例とする2値分類

問題点

局面 x は・・・

$f_{\text{SVM}}(x) > 0$  プロ棋士が選びそうな局面

$f_{\text{SVM}}(x) < 0$  そうでない局面

評価関数の値そのもの $f_{\text{SVM}}(x)$ が局面 x の優劣を表しているわけではない

 例：次局面の評価値が全て負の場合、評価値の高い局面が最善とは言えない

局面集合を**順位付け（ランキング）**する
評価関数を作成すべき！

正例と負例の2値ラベルからランキング学習ができる
ランキングSVM (Joachims '02) を用いる



ランキング SVM と評価関数

ランキングSVM

$$S = \{(\langle \mathbf{x}^+, \mathbf{x}^- \rangle, 1) \mid (\mathbf{x}^+, \mathbf{x}^-) \in \bigcup_x P(\mathbf{x}) \times N(\mathbf{x})\}$$

サンプルは**正例と負例のペア**でワンセット，**全て正例**

サンプルを正例と負例のペアとして与えることで，ランキング問題を2値分類問題に還元

$f_{\text{RSVM}}(\mathbf{x}^+) > f_{\text{RSVM}}(\mathbf{x}^-)$
となるような学習が行われる

SVM

$$\begin{aligned} \psi(\langle \mathbf{x}^+, \mathbf{x}^- \rangle) \\ = \phi(\mathbf{x}^+) - \phi(\mathbf{x}^-) \end{aligned}$$


ランキングから2値分類への還元を行うための写像

$$\hat{f}(\langle \mathbf{x}, \mathbf{x}' \rangle) = \mathbf{w} \cdot (\phi(\mathbf{x}) - \phi(\mathbf{x}'))$$

$$f_{\text{RSVM}}(\mathbf{x}) = \mathbf{w} \cdot \phi(\mathbf{x})$$

ランキングと将棋

ランキングから2値分類に還元する際、一般には全ての正例と負例のペアからなるサンプルを作るため**サンプル数が2乗に増大**するが、将棋においては**次局面の集合内でのみペアを作成すればよいのでほぼ増大なし**





実装 & 実験

Pegasos (Shai-Shwartz ら '08)

- * Primal Estimated sub-GrAdiend Solver for SVM
- * ランダムサンプリングと勾配法を用いたシンプルなアルゴリズム
- * 逐次学習（大規模データでも大丈夫）
- * 計算時間がサンプル数に依存しないので高速

今回実験で用いたデータ（棋譜5万局分）
は正例負例合わせて**4億例**（750GB）

実験（駒組みの観察）

- 5万局の棋譜をサンプルとした $f_{\text{SVM}}, f_{\text{RSVM}}$
- 指定局面を3つ用意し, $f_{\text{SVM}}, f_{\text{RSVM}}$ の上位3手を比較

9	8	7	6	5	4	3	2	1	
香	桂				金	銀	桂	香	一
	飛		銀	金		玉	角		二
歩			歩	歩	歩	歩	歩	歩	三
		歩	歩	歩					四
	歩								五
		歩	歩						六
歩	歩	角		歩	歩	歩	歩	歩	七
		銀	飛				玉		八
香	桂		金		金	銀	桂	香	九

A

9	8	7	6	5	4	3	2	1	
香	桂		金				桂	香	一
	王	銀		金	飛				二
	歩	歩		歩	銀	歩	角	歩	三
歩			歩			歩			四
					歩		歩		五
		歩	歩	歩					六
歩	歩	角		銀	歩	歩		歩	七
香				金			飛		八
玉	桂	銀	金				桂	香	九

B

9	8	7	6	5	4	3	2	1		
香	桂						王	桂	香	一
	飛		銀				金		二	
歩			歩			金	銀	歩	歩	三
	歩	歩	角	歩	歩	歩	歩		四	
									五	
		歩	歩	歩			歩		六	
歩	歩	銀				歩	銀	歩	歩	七
	玉	金	角	金			飛		八	
香	桂						桂	香	九	

C

多項式カーネルは10次, λ は0.001, ϵ は0.01
 逐次学習における更新回数は10万回として学習を行った

実験結果

	評価順位	SVM	ランキング SVM
局面A	1	6五歩	8八角
	2	4六歩	4八銀
	3	3八飛	3八銀
局面B	1	3六歩	7八金
	2	8八玉	8八銀
	3	6八金左	7八銀
局面C	1	6七金	2六歩
	2	4八金	4六角
	3	5九金	4六銀

第一候補手にあまり差はないが、ランキング学習を用いたほうが、まともな手を多く上位に含んでいる

実験（棋譜との一致率）

- * 1000 局の棋譜をサンプル
- * Pegasos のパラメータ λ を 0.01, 0.05, 0.1, ϵ を 0.001, 0.01 と変化させて f_{SVM} , f_{RSVM} を作成（全 16 個）
- * 更新回数は $1/\lambda\epsilon$
- * テストデータは 100 局分（10521 局面）
- * それぞれの評価関数により選択された第 n 候補までの次局面の中に、棋譜における局面と同一の局面含まれていれば一致

実験結果


$\epsilon = 0.001$

λ	n	SVM	RSVM
0.01	1	0.05646	0.05826
	2	0.11910	0.14560
	3	0.16319	0.20141
0.05	1	0.05655	0.06321
	2	0.11833	0.13687
	3	0.16291	0.19428
0.1	1	0.05646	0.04857
	2	0.11891	0.11948
	3	0.16253	0.17185

$\epsilon = 0.01$

λ	n	SVM	RSVM
0.01	1	0.05589	0.05057
	2	0.11795	0.11643
	3	0.16206	0.17166
0.05	1	0.05646	0.03840
	2	0.12090	0.10959
	3	0.16415	0.15597
0.1	1	0.05807	0.05617
	2	0.11976	0.13117
	3	0.16434	0.17394

実験結果



まとめ & 今後の課題

まとめ

- 多項式カーネルを用いたことによる特徴の自動生成
- ランキング SVM を用いた評価関数の学習

今後の課題

- minimax 探索を組み込んだ学習
- 内積計算の高速化