

Feature Low Rank Modelによる勝率予測を用いた ゲームAIにおけるデッキ構築アルゴリズムの研究

研究背景

- デッキ構築
既定のカード集合CからCの要素とその数からなるカードの多重集合「デッキ」を生成するプロセス
- 機械学習を用いたデッキ構築研究の目的
機械学習によってプレイヤーの勝率を向上させる
デッキ構築を事前知識なしに達成
→プレイヤーの手本やカードゲーム作成の補助への応用
- 研究の障害
候補解の評価値計算に用いる勝率を調査するための対戦シミュレーションの計算コストが高い
- 研究目的
 - ・GAを用いたデッキ構築において勝率予測による評価値の近似と計算の高速化が有効か調査
 - ・組み合わせや対称性を明示的に扱うなどの近似に用いるモデルの特徴がデッキ構築に与える影響を調査

使用手法

- 使用した機械学習モデル
Feature Low Rank Model (FLR)
特徴
 - ・各アイテムの付加情報とその相互作用を扱う
 - ・対称性モデルの入力: i, j
モデル式:
$$E_{ij} = f_i^T w + f_i^T W f_j$$
$$\Pr(i \text{ beats } j) = S(E_{ji} - E_{ij})$$
$$F = [f_1 \quad \dots \quad f_n]: \text{各アイテムに対応する既知の特徴ベクトルを保存した特徴行列}$$
$$S(x): \text{シグモイド関数 } \frac{1}{1 + \exp(-x)}$$
$$\Pr(i \text{ beats } j): i \text{ が } j \text{ に勝利する勝率}$$
$$w, W: \text{未知の潜在的なパラメータ。学習によって求める}$$

実験設定

- タスク
有名なデッキ構築型ゲーム「ハースストーン」における指定のデッキ群に対して評価値を最大化するデッキ生成
- 評価値
デッキ群に属する各デッキに対するシミュレータ上での勝率の最小値
- 実験概要
 1. 機械学習によって任意のデッキ対の対戦における勝率を予測する予測機を作成
 2. 評価値の近似に予測機を用いたデッキ生成
 3. 指定のデッキ群と対戦シミュレーションを行い評価
- 対戦相手として想定するデッキ
競技的なデッキ2種類とランダムに生成したデッキ1種類

今後の研究

- 対称性のないモデルとFLRの比較
- デッキ構築問題の特徴を反映しない多層パーセプトロンとの比較
- 3次以上の高次の組み合わせの相互作用を考慮したモデルとの比較

実験

実験1

タスク: デッキ1つに対して有効なデッキの生成

○実験結果

行: 使用したモデルと最適化手法

列: 対戦相手として想定したデッキ

要素: 生成されたデッキの縦軸のデッキに対する勝率

	デッキ1	デッキ2	ランダム生成デッキ
対称線形モデル with GA	78%	23%	57%
FLR with MILP	92%	84%	84%
FLR with GA (デッキ内相互作用の考慮無)	92%	82%	79%
FLR with GA (デッキ内相互作用の考慮有)	96%	61%	70%

実験2

タスク: 実験1で対戦相手として使用した3つのデッキすべてに対して有効なデッキの生成

○実験結果

行: 使用したモデルと最適化手法

列: 対戦したデッキ

要素: 生成されたデッキの縦軸のデッキに対する勝率

	デッキ1	デッキ2	ランダム生成デッキ
対称線形モデル with GA	78%	23%	57%
FLR with GA (デッキ内相互作用の考慮無)	95%	83%	88%
FLR with GA (デッキ内相互作用の考慮有)	82%	71%	87%

考察

- GAを用いたデッキ構築において勝率近似による評価値計算の高速化が有効か調査
→FLRを用いた予測機を使った実験では、対戦相手として考慮したデッキに対して高い勝率を達成
- 組み合わせや対称性を明示的に扱うモデルの使用がデッキ構築にどのような影響を与えるか調査
→組み合わせの考慮を行わない対称線形モデルと組み合わせの考慮を行うFLRモデル間の明確な勝率の差を確認