

バドミントンにおけるショット予測精度向上 のためのゲームツリーモデルの拡張

Extension of a Game Tree Model for Improving Shot Prediction Accuracy in Badminton

美濃岡 知樹[†] 折原 良平[†] 田原 康之[†] 大須賀 昭彦[†] 清 雄一[†]
Tomoki Minooka Ryohei Orihara Yasuyuki Tahara Akihiko Ohsuga Yuichi Sei

1 はじめに

近年、スポーツ分析の分野では、ゲーム理論に基づく行動の評価や予測の研究が活発に行われている。特にラケットスポーツは、自身と対戦相手の行動が交互に繰り返されるスポーツであり、両選手の間に明確な相互作用と相互依存関係が存在するため、ゲーム理論を用いた研究との親和性が高い。このような戦術的な意思決定をモデル化する手法の一つとして、ゲームツリーを用いた研究がある。ラケットスポーツの一つであるバドミントンでは、実際の試合データからラリーの展開を木構造として表現することで、選手の次のショットを予測する研究が行われている [1]。

しかし従来のゲームツリーは、実際の試合で行われたラリーをもとに構築されており、ツリーに存在しないラリーについては予測ができないという課題があった。またこのようなゲームツリーを構築する際には、各ノードの利得値の計算に用いられる、ショットの価値を適切に設定する必要がある。従来の研究では、各試合のセット数やラリー数に応じてそのショットの価値が算出されており、個々のショットがラリーの勝利にどれほど貢献したかが十分に反映されていなかった。

一方で、近年ではスポーツデータに機械学習技術を適用し、選手の行動や戦術を評価する研究が進んでいる。特に深層強化学習を用いた手法では、過去のバドミントンの試合データから選手の行動(ショット)に対して価値を割り当て、そのショットのラリー勝利への貢献度を定量的に評価することが可能となっている [2]。このようなアプローチは、戦術の分析や選手指導の支援において有効であるとされている。

そこで本研究では、バドミントンの試合における各ショットのラリー勝利への貢献度を、深層強化学習により定量的に評価し、その行動価値をショットの利得値としてゲームツリーに組み込む手法を提案する。また、実際のラリーを基に擬似的なラリーを生成し、それらもツリーに追加することで、ゲームツリーの拡張を行う。これにより、従来のツリーでは表現できなかったラリーにも対応が可能となり、より柔軟かつ高精度な予測が実現できる。本研究によって、選手の戦術的な行動を正確に評価し、従来のゲームツリーを超えて未知のラリーにも対応する予測モデルの構築が可能となった。ゲームツリーによるショットの予測は、過去の試合データの分析やラリーのシミュレーションなどで、戦術の決定や選手への指導などに活用されることが期待できる。

2 関連研究

2.1 試合データを用いたゲームツリー構築

Liuらは、ゲームツリーを用いて、バドミントンの試合における選手の戦術のモデル化を行った。ツリーの各ノードがショットを表していて、各ノードにおける子ノードの利得値を参照することで、ラリーの勝率の予測やショットの予測を行った。この各ノードの利得値を算出するために、試合データのすべてのショットそれぞれに利得値を計算する必要がある。この研究では、ショットの利得値は、試合やラリーの終盤のショットであるほどラリーの勝敗に大きく影響するという考えから、試合後半のショットほど高い利得値が付与された。

しかしこの計算方法では、試合中の選手の位置などのコート上の情報が反映されていないことや、ラリー前半や中盤の重要なショットが見落とされてしまうなど、ラリーの勝利に本当に貢献したショットの評価が利得値に

[†] The University of Electro-Communications

反映されないといった課題がある。実際の試合では、選手は相手の動きや試合状況を踏まえて戦術を調整しながらプレーしているため、戦術の選択が試合結果に与える影響は大きいと考えられる。そのため選手の各ショットを正しく評価できれば、ゲームツリーを用いた最適なショットの予測精度をさらに向上させる可能性がある。

2.2 深層強化学習による選手評価

Ding らは、バドミントンにおける選手の行動価値を推定し、選手を評価するモデルを提案した。この研究では、強化学習手法の 1 つである SARSA を用いて Q 値を推定するための LSTM ネットワークを構築した。モデルへの入力には、選手の位置、選手の姿勢、シャトルの位置、ショットの種類などの情報をシーケンスデータとして用い、各ショットの価値を評価した。推定された行動価値は、試合のスコアや選手のランクとの相関関係が確認され、その有用性が示された。選手の行動価値の評価は、各ショットがラリーの勝利にどれだけ貢献したかを示すものであり、選手の戦術分析に活用できる。

3 提案手法

3.1 アプローチの概要

アプローチの概要を図 1 に示す。本研究では、まずバドミンントンの試合データを基に、深層強化学習により試合における選手の各ショットの行動価値を計算する。次に試合データから擬似的なラリーを生成した上で、拡張されたゲームツリーを構築する。このとき、深層強化学習により導出した行動価値を各ショットの利得値としてゲームツリーに組み込む。最終的に、構築されたゲームツリーを用いて、ショットの予測を行うことを目的としている。

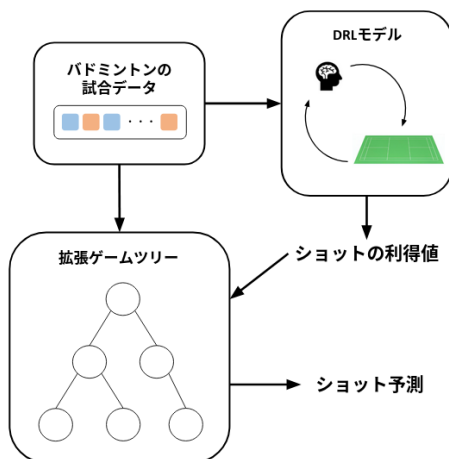


図 1 アプローチの概要

3.2 選手の行動価値を導出する深層強化学習モデル

本研究では、Ding らの選手評価モデル [3] をもとに、選手の行動価値を導出する深層強化学習モデルを構築する。モデルの入力には、バドミンントンの試合映像をもとに各ショットごとにアノテーションされたデータを用いる。状態 s_t には、時刻 t における両選手の位置としてコート上の XY 座標、シャトルの位置の XY 座標、ショットを打つ選手のラベルを含む情報を入力として与える。行動 a_t には、9 種類のショットタイプ (サーブ、クリア、ドロップ、スマッシュ、ドライブ、レシーブ、ロブ、ネット、プッシュ) のいずれかが選択される。

行動価値の推定には、LSTM ネットワークを用いた関数近似により Q 関数の学習を行う。Q 値の更新は、実際の行動をもとに行う SARSA(State-Action-Reward-State-Action) アルゴリズムに基づき、以下の式で行う。

$$Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha [R + \gamma Q(s_{t+1}, a_{t+1}) - Q(s_t, a_t)] \quad (1)$$

ここで α は学習率、 γ は割引率を表す。また Q 学習の報酬 R は、ラリーが終了した際にそのラリーの勝者に正の報酬を与える。これにより、実際にラリーに勝利した選手が、そのラリーの得点を獲得する確率を Q 値として推定する。なお、サーブを行う前 ($t = 0$) の、両選手が得点を獲得する確率 (Q 値) は 0 とする。

式 (1) により推定した Q 値をもとに、選手の各行動の価値 A は次のように計算する。この値を、そのショットの利得値として、ゲームツリーの構築に用いる。

$$A_{t+1} = Q(s_{t+1}, a_{t+1}) - Q(s_t, a_t) \quad (2)$$

3.3 ゲームツリーの構築

バドミンントンの試合は複数のラリーの集合で構成されており、ラリーは複数のショットのシーケンスデータとして表すことができ、各ショットは選手がとる戦術として考えることができる。ここで全てのショットは、9 種類のショットタイプとそのショットを打ち込んだコートの領域 (左右の 2 値) の組み合わせで表現される。

ここで、ゲームツリー構築の具体的なアルゴリズムについて、ラリーの例 $R_e = \{r_1, r_2\}$ を用いて示す。なお、ショットはショットタイプとショットを打ち込んだ左右どちらかの位置 (L or R) で表す。

$$\begin{aligned} r_1 &= \{\text{サーブ (R)}, \text{ネット (R)}, \text{ネット (R)}, \text{ロブ (L)}\} \\ r_2 &= \{\text{サーブ (R)}, \text{ネット (R)}, \text{ロブ (L)}, \text{クリア (L)}\} \end{aligned}$$

まずルートノード N_0 を作成し、ルートノードに r_1 を追加する。この時、各ショットはゲームツリーのノードとなる。作成されたノードを上から順に N_1, N_2, N_3, N_4 とする。次に r_2 をゲームツリーに追加する。ここで、最初のショットであるサーブ (R) は N_0 の子ノードである N_1 と同じショットであるため、サーブ (R) は同じノード N_1 に追加される。同様に次のショットであるネット (R) も N_1 の子ノードの N_2 に追加する。次のショットであるロブ (L) は N_2 の子ノードに存在しないため、新しく子ノード N_3 を作成し、以降のショットもノードを作成して追加する。

次に、ゲームツリー拡張のため、以下のように与えられたラリーから最初のショットを削除して、ラリーの長さが 2 以下になるまで疑似ラリーを作成する。

$$r'_1 = \{\text{ネット (R)}, \text{ネット (R)}, \text{ロブ (L)}\}$$

$$r''_1 = \{\text{ネット (R)}, \text{ロブ (L)}\}$$

$$r'_2 = \{\text{ネット (R)}, \text{ロブ (L)}, \text{クリア (L)}\}$$

$$r''_2 = \{\text{ロブ (L)}, \text{クリア (L)}\}$$

作成された疑似ラリーも、ルートノード N_0 の子ノードとして追加する。すべてのラリーについて、該当のショットが子ノードに存在すればそのノードに追加し、なければ新しく子ノードを作成して追加する。以上の方法により、2 つのラリー $R_e = \{r_1, r_2\}$ により構築されたツリーを図 2 に示す。

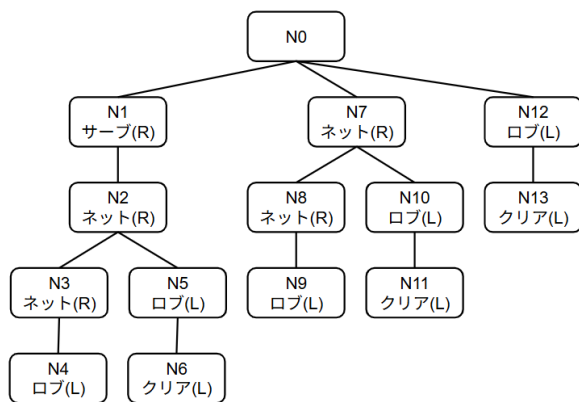


図 2 ゲームツリー構築の例

構築したゲームツリーの各ノード N には、ショットの予測のために利得値を付与する。ノードの利得値は、そのノードに分類されたショット $s_i \in S(N)$ の利得値の和で求められる。

3.4 ゲームツリーの探索

構築したゲームツリーを探索し、各ノードの利得値を参照することで、ショットの予測を行う。予測の対象となるラリーのうち、実際に予測を行うショットの 1 個前までのラリーでゲームツリーを探索し、最後に到達したノードの子ノードの中から、利得値が大きい上位 k 個のノードを、予測結果の候補として出力する。

予測対象ラリーと同じラリーがゲームツリーに存在せず最後まで探索できない場合や、子ノードが k 個未満の場合は、ラリーの最初のショットを除外した上でもう一度探索を行う。例えば図 2 のゲームツリーを予測対象ラリー $r_t = \{\text{サーブ (R)}, \text{ロブ (L)}, \text{クリア (L)}\}$ で探索を行う場合、 N_1 のサーブ (R) までは探索を行えるが、 N_1 の子ノードにロブ (L) が存在しない。その場合は $r'_t = \{\text{ロブ (L)}, \text{クリア (L)}\}$ で再度探索を行う。

4 実験

本研究では、従来手法で構築したゲームツリー [1] をベースラインとして、深層強化学習により導出したショットの利得値を用いたゲームツリーでのショットの予測精度との比較を行った。

4.1 データセットと前処理

データセットには ShuttleSet[4] を用いた。ShuttleSet は 2018 年から 2021 年にかけて行われた 27 人のトップランキングの男子シングルス及び女子シングルの選手による 44 試合、104 セット、3685 ラリー、36492 ショットが含まれているデータセットである。各ショットに対して、ショットを打った選手、ショットの種類、ショット時のシャトルの座標、2 人の選手の座標、そのショットが含まれるラリーの勝者と勝敗決定の理由の情報がアノテーションされている。前処理として、上記の情報のいずれかが欠損しているショットを含むラリーと、ラリーの長さが 2 未満、33 以上のラリーを削除し、合計で 2220 ラリーのデータを用いて実験を行った。

また LSTM を用いた Q 関数の学習において、学習率 $\alpha = 10^{-5}$ 、割引率 $\gamma = 0.3$ に設定した。

4.2 実験結果

データセットの各試合の、前半 80% のラリーをゲームツリーの構築に、後半 20% のラリーをゲームラリーの探索及びショットの予測に使用した。またテストラリーの一番最後のショット (最後のショットがネットやアウトなどのミスの場合は最後から 2 番目のショット) を予測対象とした。予測に用いる候補ノード数を

$k = [1, 3, 5]$ の条件で設定し、正しく予測できた割合として Accuracy を求めた。結果を表 1 に示す。

表 1 ショットの予測精度の比較

	Accuracy		
	$k = 1$	$k = 3$	$k = 5$
Liu et al.	0.316	0.656	0.809
ours	0.318	0.665	0.828

ここで表 1 におけるベースライン (Liu et al.) は、先行研究の手法による利得値計算と拡張なしのゲームツリーに基づく予測結果を示している。この手法ではツリーに存在しないラリーの予測は不可能であるため、予測対象ショットの直前に行われたショットの、次のショットとして出現度が高いものを集計した辞書を作成した。ベースラインモデルでは、ツリーで予測が不可能なラリーの場合はこの辞書を参照し、次のショットとして最も頻度の高い上位 k 個のショットを予測の候補に含めた。

4.3 アブレーションスタディ

本研究の有効性を定量的に検証するため、提案手法の比較対象として以下の 2 種類のモデルを用いてアブレーションスタディを実施した。

- **ours(no expansion)** : ゲームツリーの拡張は行わずに、ツリーに存在しないショットは辞書を参照するモデル
- **ours(no val gain)** : ゲームツリーの拡張はするものの、ショットの利得値の計算には先行研究の手法を用いるモデル

以上の 2 つのモデルと提案手法のショットの予測精度を比較した結果を表 2 に示す。

表 2 提案手法のアブレーションスタディ結果の比較

	Accuracy		
	$k = 1$	$k = 3$	$k = 5$
ours(no expansion)	0.327	0.654	0.806
ours(no val gain)	0.299	0.643	0.806
ours	0.318	0.665	0.828

5 考察

表 1 により、提案手法は全ての k 条件でベースラインを上回る精度を示した。また、表 2 の ours(no val gain) との比較でも同様に、提案手法の方が勝る結果となった。

これより、行動価値を組み込んだゲームツリーはショットの予測精度の向上に有用であると分かる。

また表 2 では、 $k = 1$ ではゲームツリーを拡張せずに辞書を使用する予測が最も高精度である一方、 $k = 3, 5$ では提案手法が最も高い精度を達成している。これは候補が 1 つの場合は頻出パターンによる予測で十分だが、予測候補が複数の場合は、ゲームツリーによりショットの利得値、つまり勝利への貢献度が候補選定に活かされ、戦術的に意味のある選択肢が予測候補に含まれるようになったからであると考えられる。このことから、ゲームツリーは勝利への貢献度を考慮した候補選定を可能とし、戦術的に意味のある適切なショットをより高精度に提示する性能を備えていることが示された。

6 おわりに

本研究では、バドミントンの試合データを基に、ショットの勝利への貢献度を組み込んだゲームツリーの構築とショットの予測を行った。結果はベースラインを上回る予測精度を実現し、貢献度を反映したゲームツリーの有用性を示した。またゲームツリーの拡張により、未知のラリーへの対応や、戦術的価値の高いショットの提案ショットの提案の可能性も示した。貢献度の高いショットの複数提案は、戦略の決定や選手の指導に役立てることが期待できる。

また今後の展望として、ツリー探索の重みづけなどの、モデルの改良による予測精度の向上や、映像処理技術を用いたリアルタイムでのショットの価値推定及び予測などを行う予定である。

参考文献

- [1] Wenming Liu, Yifan Zhu, Wenxia Guo, Xinyuan Wang, Songkun Yu, "Gaming Tree Based Evaluation Model for Badminton Tactic Benefit Analysis and Prediction" MDPI, Applied Sciences 2023, 13(13), 7380, 2023.
- [2] Ning Ding, Kazuya Takeda, Keisuke Fujii, "Deep Reinforcement Learning in a Racket Sport for Player Evaluation With Technical and Tactical Contexts" IEEE Access(Volume: 10), pp.54764-54772, 2022.
- [3] Ning Ding. https://github.com/Ning-D/Evaluate_Badminton_Stroke
- [4] Wei-Yao Wang, Yung-Chang Huang, Tsi-Ui Ik, Wen-Chih Peng, "ShuttleSet: A Human-Annotated Stroke-Level Singles Dataset for Badminton Tactical Analysis." arXiv.2306.04948, 2023.