

RoboCup Soccer Simulation 2Dを対象とした 双方向GRUによる選手とボールの軌道予測

Player and ball trajectory prediction by bidirectional GRU for RoboCup Soccer Simulation 2D

大橋 玲音¹ 鈴木 丈慈¹ 坪倉 和哉¹ 小林 邦和¹
Reon Ohashi¹ Joji Suzuki¹ Kazuya Tsubokura¹ Kunikazu Kobayashi^{1*}

¹ 愛知県立大学

¹ Aichi Prefectural University

Abstract: 本研究では、RSS2Dを対象として、選手とボールのゴール時の軌道を予測する双方向GRUモデルを構築した。訓練には2024年のRSS2D世界大会に出場した10チームの総当たり戦で生成された90,000試合のデータから抽出した237,599件のゴールのデータを用いた。また、9通りのハイパーパラメータの組み合わせを比較することで最も高精度なモデルを選定した。その結果、最良モデルは双方向GRU層が4層、中間層のユニット数が256個の構成であることが明らかになった。最終的に、テストデータに対して、最良モデルによる予測精度(終端誤差)は3.7880であった。

1 はじめに

RoboCup Soccer Simulation 2D(以下RSS2D)は、11体の仮想的なロボットで構成される2チームが対戦するサッカーシミュレーションリーグであり、複数ロボット間における協調行動の実現を通して、人工知能や機械学習の研究・開発を推進することが期待されている。

RSS2Dにおいて、ロボットやボールの移動軌跡を予測することは、戦術を決定するうえで重要な要素であると考えられる。特に、得点に直結するシュートの動きを事前に予測する能力は、自チームによる攻撃時のみならず、相手チームの攻撃に対する防御戦略を構築する上でも有用である。これまで、RSS2Dにおいては、パス先の相手の選択予測[1]やドリブル中の相手チームの移動予測[2]などの研究が行われてきた。

こうした背景のもと、選手及びボールの移動軌跡を対象とした予測精度を競う「サッカー軌道予測コンペティション」が開催された¹。サッカー軌道予測コンペティションは、Robo Cupサッカーシミュレータによって生成された試合データ[3]を用い、選手およびボールの移動軌道の予測精度を競うものである。具体的には、試合開始からゴール決定直前の3秒前までのデータを基に、ゴール決定までの選手及びボールの移動経路を予測することが求められる。モデルの性能評価指標として、終端誤差を採用している。

本稿では、コンペティションにおける予測モデルの構築および評価について報告する。提案手法としてBidirectional Gated Recurrent Unit(双方向GRU)[4, 5]を用いて選手及びボールの移動経路の予測を行うモデルを構築し、コンペティションのデータセットを用いてモデルの性能評価を行った。その結果、最良モデルによる終端誤差は3.7880となった。なお、本手法は第1回サッカー軌道予測コンペティションにおいて優秀賞を獲得した。

2 データ

本研究に用いたデータは、Robocup 2024に出場した10チーム間の総当たり戦により生成された2000試合、すなわち合計90,000試合のtracking.csvデータである。元データに含まれるカラムを表1に示す。

上記データから、ゴール直前50フレームのみを抽出してゴールデータを作成した。50フレームとした理由は、サッカー軌道予測コンペティションにおけるテストデータの最小が50フレームであることに基づく。加えて、欠損値が含まれるゴールデータは分析に不適と判断して除外した。さらに、各カラムに対して0から1の範囲で正規化を実施した。そして、各チームには整数値を割り当て、20ビットのOne-hotベクトルへ変換した。

*連絡先: 小林 邦和, 愛知県立大学 情報科学部
〒480-1342 愛知県長久手市茨ヶ廻間 1522-3
E-mail: kobayashi@ist.aichi-pu.ac.jp

¹<https://sites.google.com/view/stp-challenge/>

表 1: カラム一覧

カラム名	説明
#	フレーム番号
cycle	試合時間のカウント
stopped	試合停止中のカウント
playmode	プレイモード
[lr]_name	各サイドのチーム名
[lr]_score	各サイドの得点
[lr]_pen_score	各サイドの延長ペナルティシュートアウトでの得点
b_{x,y,vx,vy}	ボールの位置および速度
[lr][1-11]_t	各選手のプレイヤータイプ ID
[lr][1-11]_{x,y,vx,vy}	各選手の位置および速度
[lr][1-11]_body	各選手の体の向き
[lr][1-11]_neck	各選手の首の向き
[lr][1-11]_vwidth	各選手の視野角
[lr][1-11]_stamina	各選手のスタミナ

また、エージェントの挙動に対して影響が小さいと判断した以下のカラムは分析対象から除外した。

- #
- cycle
- stopped
- playmode
- [lr]_score
- [lr]_pen_score

なお、元データには左チームが得点した事例と右チームが得点した事例が混在しているため、本研究では後者については X 座標を反転させ、すべてのデータを左チームがゴールした形式に統一した。この処理によって、データセットの対称性が確保され、実質的にデータを約 2 倍に増やすことが可能となった。

これらの前処理により、最終的に 237,599 件のゴールデータが得られた。このうち 80% (190,079 件) を訓練データ、20% (47,520 件) をテストデータとして用いた。

3 提案手法

本研究では、双方向 GRU を用いて予測モデルの構築を試みた。双方向 GRU は Gated Recurrent Unit (GRU) [4] をもとに、双方向 Recurrent Neural Network (RNN) [5]

の考えに基づいて、未来方向と過去方向の双方向に情報のやり取りを行うように変更したモデルである。双方向 GRU は、交通流量予測 [6, 7] や動画検出 [8] などに用いられている。双方向 GRU 層の概要図を図 1 に示す。ここで、 x_i は i フレームでの特徴量を表し、 y は出力を表す。入力はゴール直前 50 フレーム中の前 20 フレームのデータとし、後 30 フレームをターゲットデータとして学習を行った。損失関数には予測した 30 フレームすべての特徴量に対する Mean Squared Error (MSE) を用い、最適化手法として Adam [9] を採用した。実装には PyTorch 及び PyTorch-Lightning を用いた。このモデルの入出次元は (バッチサイズ, シークエンス長, 特徴量数) であり、本実験では入力長は (512, 20, 223)、出力長は (512, 30, 223) である。




図 1: 双方向 GRU 層の概要図

3.1 ネットワーク構成

提案モデルは、以下の層構成を採用している。提案モデルの概要図を図 2 に示す。

1. **入力層**: 各フレームの特徴量をそのまま入力とする。各入力ベクトルは正規化済みの実数値で構成される。
2. **双方向 GRU 層**: 双方向 GRU 層を複数層重ねる。
3. **全結合層**: 双方向 GRU 層の出力を後続の全結合層に入力し、ターゲットフレームの位置情報を推定する。




図 2: 提案モデルの概要図

4 実験

実験では、双方向 GRU の層数が 4 層および 8 層、並びに中間層のユニット数が 128 と 256 のモデルを比較検証し、最良の性能を示した構成を採用した。全 200 エポックにわたる訓練を実施し、テストデータにおいて最小の終端誤差を示したエポックのモデルを最終的なモデルとした。終端誤差は、コンペティションの最終的な評価に用いられる評価指標であり、ゴール決定フレームにおけるボールおよび得点側選手の位置におけるユークリッド距離の誤差の平均である。具体的な式を以下に示す。

$$\frac{\sqrt{(x_{\text{acc,ball}} - x_{\text{pred,ball}})^2 + (y_{\text{acc,ball}} - y_{\text{pred,ball}})^2}}{12} + \frac{\sum_{i=1}^{11} \sqrt{(x_{\text{acc},i} - x_{\text{pred},i})^2 + (y_{\text{acc},i} - y_{\text{pred},i})^2}}{12}$$

ここで、 $x_{\text{acc,ball}}$ および $y_{\text{acc,ball}}$ は実データのボールの x 座標と y 座標を、 $x_{\text{pred,ball}}$ および $y_{\text{pred,ball}}$ は予測データのボールの x 座標と y 座標を、 $x_{\text{acc},i}$ および $y_{\text{acc},i}$ は実データの i 番目のプレイヤーの x 座標と y 座標を、 $x_{\text{pred},i}$ および $y_{\text{pred},i}$ は予測データの i 番目のプレイヤーの x 座標と y 座標をそれぞれ表す。

4.1 ハイパーパラメータ設定

モデルの学習には、以下のハイパーパラメータを設定した。ただし、これらの値は経験則的に求めたものであり、最適なパラメータではない可能性がある。

- **学習率**: Adam オプティマイザを用い、初期学習率は 0.001 とした。

- **バッチサイズ**: 512 件ずつのバッチで学習を実施した。
- **エポック数**: 200 エポックで訓練を行い、各エポック毎にテストデータで終端誤差を評価した。

4.2 ネットワーク構成

本実験では、モデル構築における各ハイパーパラメータ（双方向 GRU の層数、中間層のユニット数）について、表 2 の設定でグリッドサーチを行い、最適なハイパーパラメータを求めた。

表 2: ネットワーク構成一覧

モデル構成	双方向 GRU の層数	中間層のユニット数
モデル 1	4 層	128 ユニット
モデル 2	4 層	256 ユニット
モデル 3	4 層	512 ユニット
モデル 4	6 層	128 ユニット
モデル 5	6 層	256 ユニット
モデル 6	6 層	512 ユニット
モデル 7	8 層	128 ユニット
モデル 8	8 層	256 ユニット
モデル 9	8 層	512 ユニット

4.3 結果

学習過程における訓練データとテストデータの MSE と終端誤差の推移を図 3, 4, 5, 6 にそれぞれ示す。また、各モデルの最も優れていたエポックの評価結果を表 3 および図 7, 8 にまとめる。実験結果から、4 層・256 ユニット数の構成が最も良好な評価結果を示し、テストデータにおける終端誤差の最小値を記録した。また、双方向 GRU 層は 8 層や 6 層より 4 層のほうが評価が高く、中間層のユニット数は 128 個や 512 個より 256 個のほうが優れていることが判明した。また、モデル 3, 5, 6, 7, 8, 9 は学習過程において MSE 及び終端誤差が大きく上昇する現象ことが確認された。

モデル 3, 5, 6, 7, 8, 9 は学習過程において MSE 及び終端誤差が大きく上がった理由として、モデルのパラメータ数が増えたことによる学習の不安定性の増加が原因と考えられる。また、この最良モデルによって得られた予測図の例を図 4.3, 4.3 に示す。それぞれ、実線と \circ 印が実際のデータで、 \times 印と点線が予測データを表す。赤色が左チーム、緑色が右チーム、青色がボールをそれぞれ表す。




図 3: 訓練データにおける MSE の推移




図 6: テストデータにおける終端誤差の推移




図 4: テストデータにおける MSE の推移

表 3: 各モデル構成の評価結果

モデル構成	MSE	終端誤差
モデル 1	0.0244	3.9990
モデル 2	0.0242	3.7880
モデル 3	0.0245	4.1299
モデル 4	0.0246	4.0942
モデル 5	0.0244	4.0335
モデル 6	0.0245	4.2001
モデル 7	0.0251	4.5604
モデル 8	0.0245	4.3209
モデル 9	0.0258	4.7757




図 5: 訓練データにおける終端誤差の推移




図 7: モデルごとの MSE の比較




図 8: モデルごとの終端誤差の比較




図 9: 予測図 (例 1)




図 10: 予測図 (例 2)

5 まとめ

本研究では、双方向 GRU を用いた RoboCup サッカー軌道予測モデルを構築し、複数のハイパーパラメータを比較することで最も高精度なモデルを選定した。その結果、双方向 GRU が RSS2D の選手とボールの軌道予測に適していることと、最適な双方向 GRU のパラメータは総数が 4 層、中間層ユニット数が 256 であることが明らかになった。

今後の課題として以下の点があげられる。

- **イベント情報の活用:** RoboCup の試合データのうち、`.event.csv` にはパスやキックといったイベント情報が含まれるが、本研究ではこれらの情報は活用していない。こうしたイベント情報の組み込みを行うことで、より精度を高めることが期待できる。
- **その他のモデルとの比較:** 今回は時系列データが扱え、かつ比較的計算コストの低い双方向 GRU を用いたが、LSTM[10] や Transformer[11] といった他のモデルと比較する。

今後はこれらの手法の検討を進めることで、さらなる予測精度の向上を目指す。

参考文献

- [1] 天野巧巳, 内種岳詞, 岩田員典, 伊藤暢浩. Rss2d における期待ポゼッション値の有効性に関する一考察. 人工知能学会第二種研究会資料, Vol. 2022, No. SAI-045, p. 01, 2023.
- [2] Dmitriy A Petrunenko and Sergej A Belyaev. Prediction of the opponents actions in soccer simulation based on location of players. In *2024 XXVII International Conference on Soft Computing and Measurements (SCM)*, pp. 299–303. IEEE, 2024.
- [3] Hidehisa Akiyama and Tomoharu Nakashima. Soccer gameplay data generation: Toward integrating computer simulations and human sports analysis, 2024.
- [4] Kyunghyun Cho, Bart Van Merriënboer, Caglar Gulcehre, Dzmitry Bahdanau, Fethi Bougares, Holger Schwenk, and Yoshua Bengio. Learning phrase representations using rnn encoder-decoder for statistical machine translation. *arXiv preprint arXiv:1406.1078*, 2014.

- [5] Mike Schuster and Kuldip K Paliwal. Bidirectional recurrent neural networks. *IEEE transactions on Signal Processing*, Vol. 45, No. 11, pp. 2673–2681, 1997.
- [6] S. Wang, C. Shao, J. Zhang, Y. Zheng, and M. Meng. Traffic flow prediction using bidirectional gated recurrent unit method. *Urban Informatics*, Vol. 1, No. 1, p. 16, 2022. Epub 2022 Dec 1.
- [7] Song Liu, Wenting Lin, Yue Wang, Dennis Z. Yu, Yong Peng, and Xianting Ma. Convolutional neural network-based bidirectional gated recurrent unit–additive attention mechanism hybrid deep neural networks for short-term traffic flow prediction. *Sustainability*, Vol. 16, No. 5, 2024.
- [8] Abdarahmane Traoré and Moulay A. Akhloufi. *2D Bidirectional Gated Recurrent Unit Convolutional Neural Networks for End-to-End Violence Detection in Videos*, p. 152–160. Springer International Publishing, 2020.
- [9] Diederik P Kingma and Jimmy Ba. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014.
- [10] Sepp Hochreiter and Jürgen Schmidhuber. Long short-term memory. *Neural computation*, Vol. 9, No. 8, pp. 1735–1780, 1997.
- [11] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N Gomez, Łukasz Kaiser, and Illia Polosukhin. Attention is all you need. *Advances in neural information processing systems*, Vol. 30, , 2017.