

RoboCup サッカーにおける時系列数値データを用いた試合状況の評価

Evaluating Game Situations with Time Series Numerical Information for RoboCup Soccer

鈴木 雄大, 中島 智晴

Yudai Suzuki, Tomoharu Nakashima

大阪府立大学大学院 人間社会システム科学研究科

Osaka Prefecture University

yudai.suzuki@kis.osakafu-u.ac.jp

tomoharu.nakashima@kis.osakafu-u.ac.jp

Abstract

We propose a method that evaluates the game situation from time series numerical information for RoboCup soccer simulation. Training data are generated by assigning a target value to each field situation according to the number of frames until the next goal. A set of consecutive frames are used to train an evaluation model. We employ a recurrent neural network as this model. We compare the performance of the constructed recurrent neural network model with the previous models and also investigate the performance of recurrent neural networks and the other models through a series of computational experiments.

1 はじめに

スポーツにおいて試合の優勢, 劣勢を把握することは重要である. 試合状況を定量的に評価できれば, 優勢度合を正確に把握することができる. しかし, 刻々と変化する複雑な試合状況において定量的な評価は困難である. そのため, 試合状況を定量的に評価する必要があるスポーツの自動実況などの研究は未だ十分な成果を挙げていない. この問題に対し, 機械学習手法の適用により試合状況の定量的な評価方法を提案する.

本研究の実験環境として, サッカーのシミュレーション環境である RoboCup サッカーシミュレーション 2D リーグ [1] を扱う. Nakashima ら [2] は, 試合中の単一局面である 1 フレームの画像に対して Convolutional Neural Network (CNN), また, 1 フレームから得られるプレイヤーの位置座標などの数値情報に対して Fully-Connected Neural Network (FCNN) を用いることで試合状況を定量的に評価できることを示した. しかし, 試合は動的に展開

していくため, 1 フレームの単一局面情報だけではそれまでの試合の流れを捉えることができない. そこで, 時系列データとして複数フレームの情報を用いることで, 試合の流れを踏まえたより正確な試合状況の評価が可能であると考えられる.

本論文では, 試合の流れを考慮した試合状況の定量的な評価に対して, 時系列データを扱うことができる Recurrent Neural Network (RNN) を用いることを提案する. これにより, より正確な試合状況の評価を目的とする. 数値実験では, 先行研究 [2] で用いられた手法の結果と, 数値情報に対して RNN を用いた結果を比較し, 時系列データを扱うことの有用性を検討する.

2 RoboCup サッカー

RoboCup [1] は, ロボット工学と人工知能の発展を目的とし, 自律移動型ロボットによるサッカーなどを題材とした研究プロジェクトである. その中の 1 つである RoboCup サッカーには, 実機を用いたリーグやコンピュータ内でのシミュレーションによるリーグなど様々なリーグが存在している. 本研究では, RoboCup サッカーシミュレーション 2D リーグを研究対象とする.

RoboCup サッカーシミュレーション 2D リーグでは実機を使用せず, コンピュータ内に用意された二次元平面を仮想サッカーフィールドとし, 円形のエージェントをプレイヤーとして競技を行う. プレイヤは, 実際の人間のようにそれぞれ独立したエージェントとしてプログラムされており, kick, dash, turn などの抽象化されたコマンドを基本行動とする. また, プレイヤやボールの位置と速度は全て二次元ベクトルとして表される. 試合は前半 3000 サイクルずつの合計 6000 サイクルからなり, 周期 0.1 秒の 1 サイクルで離散化されている. また, 試合終了後には各サイクルにおけるプレイヤーやボールの位置座標など全ての試合情報が文字列で記載されたゲームログが出力される. 本研究では, このゲームログから各サイクルにお

けるボールの位置座標と全プレイヤーの位置座標，身体の角度を抽出した数値情報を数値データとして扱い，各サイクルでキャプチャした試合画面を画像データとして扱う．Figure 1 に数値データ，Figure 2 に画像データの例を示す．

Ball	: pos x , pos y
Player1	: pos x , pos y , angle
Player2	: pos x , pos y , angle
	: \vdots
Player22	: pos x , pos y , angle




図 1: Numerical data.

図 2: Image data.

近年の競技会の傾向として，RoboCup サッカーシミュレーション 2D リーグでは，各チームが多様な戦術を用いる．それに伴い，相手戦術との相性が試合結果に大きな影響を与える．この問題への対応策として，相手戦術と相性の良い戦術への切替が求められる．相手戦術に合わせた戦術切替を行うためには相手の戦術を見分ける必要がある．そこで Nakashima ら [3] は，パスやドリブルなどのキックを抽出したキック分布を用いて相手戦術の識別を実現した．

3 試合状況の評価

一般的にチームの優勢度合を判断する指標として，どちらのチームがボールを持っているか，また各チームのプレイヤーがフィールドのどこに位置しているかなどが考えられる．しかし，このような指標のみでは優勢度合を正確に把握できないため，定量的な評価を表現する指標が求められる．先行研究 [2] では，定量的に試合状況の評価する指標として *Situation Score* を定義した．これを各フレームの試合状況に対する教師出力として，機械学習手法に用いる．試合状況を表す情報として第 2 章で挙げた画像や数値データを使う．

3.1 Situation Score

任意のフレーム f における評価値 *Situation Score* は以下の式で定義される：

$$Situation Score(f) = \pm(100 - n), \quad (1)$$

n は f から次に得点するまでのサイクル数を表す．本研究では，*Situation Score* が -100 から 100 までのフレームのみを評価対象とする．つまり，ゴールする 100 サイクル前からゴールするまでのフレームが評価対象となる．単一局面情報を用いる場合は，評価対象である 1 フレームのみを用いてそのフレームの評価を行う．時系列データを用いる場合は，評価対象の 1 フレームと前フレームを用いて，評価対象の 1 フレームの評価を行う．*Situation Score* の符号は，左チームが次にゴールする場合は正，右チーム

が次にゴールする場合は負とする．Figure 3 に左チームがゴールする 19 サイクル前のフレームとそれに対する *Situation Score* を例として示す．




図 3: Image taken 19 frames before the left team scores. The value of *Situation Score* is +81.

3.2 単一局面情報を用いた評価 [2]

先行研究 [2] では，FCNN や CNN を用いて，単一局面である 1 フレームの数値や画像データを入力とし，*Situation Score* を出力するモデルを構築した．Figure 4 に単一局面情報を用いた CNN モデルの構造を示す．これにより，試合状況の定量的な評価モデルが構築可能であることが示された．




図 4: CNN for evaluating the game situation.

3.3 時系列データを用いた評価

本論文では，時系列データを用いた試合状況の定量的な評価を提案する．複数フレームを時系列データとして捉え，それを扱うことができるモデルとして RNN が挙げられる．RNN は，時系列データを扱えるニューラルネットワークの 1 つであり，時刻 $t-1$ の隠れ層の出力値を次の時刻 t の隠れ層に入力する構造をもつ．

Aida ら [4] は，自動車の自動運転への適用を見据え，周辺の自動車の軌跡予測を RNN を用いて実現した．また，ヘルスケア分野においても Edward ら [5] は，電子カルテに記入される膨大な時系列データを用いて，RNN による患者に対する医師の診断や投薬順序の予測が可能であることを示した．Zhiyuan ら [6] は，RNN の一種である Long Short-Term Memory (LSTM) を用いることで，自動車の軌跡予測よりも経路上の地点情報が疎らなため難しいとされる，飛行機の軌道予測に対して従来手法を上

回る精度を示した. Alexandre ら [7] は, 複数の人物が存在する状況下で各人物を追跡する問題に対し, 各人物に近隣の人物の情報を共有する Social Pooling を導入した LSTM により群衆における人物追跡を実現した.

本論文では, 時系列数値データを扱うモデルとして RNN を用いる. Figure 5 に $n + 1$ フレームの数値情報からなる時系列データを用いた RNN による試合状況評価の概要を示す. 時系列データとして複数フレームの情報を扱うことで試合の流れを踏まえ, より正確な *Situation Score* による試合状況の評価が可能であると考えられる.




図 5: Abstract of evaluating the game situation by RNN.

4 数値実験

単一局面情報を用いた評価には, 数値データに対して FCNN, 画像データに対して CNN を用いる. また, 時系列データを用いた評価には数値データに対して RNN を用いる. 実験により, 教師出力値となる *Situation Score* に対するそれぞれのモデルの予測精度を比較する. また, 得られた結果に対し考察を述べる.

4.1 データセット

先行研究 [2] と同様の手順でデータセットを作成する. データセット作成にあたり, 多くの状況やフォーメーション, 戦術を考慮するために 16 チームでサッカーを行い, ゲームログを生成する. 16 チームは先行研究 [2] で用いられたチームと同様の 2016 年 RoboCup 世界大会出場チームとする. ゲームログより, ゴールしたサイクルから 100 サイクル前までの情報を抽出する. そして抽出した全ての情報 (数値データと画像データ) に対して, *Situation Score* を教師出力値とする.

4.2 実験設定

実験に用いるデータを準備するため, まず, 16 チームの各組 50 試合の計 6000 試合よりゴールしたサイクルから 100 サイクル前までの 928,200 フレーム (9,282 ゴール \times 100 サイクル) を抽出する. 次に, そのデータを学習用, 検証用, テスト用に分割する. データの分割内訳を, 学習用データ: 660,000 フレーム, 検証用データ: 143,700 フレーム, テストデータ: 124,500 フレームとした. 性能評価指標として, モデルの出力値と教師出力値の平均絶対誤差 (MAE) を用いる.

4.2.1 単一局面情報 (先行研究)

数値データを用いる際, 画像データとの整合性を図る必要がある, そこで, 1 フレームの画像から視覚的に得ることができる情報である, 各サイクルにおけるボールの座標 (b_x, b_y) , 22 体のプレイヤーの位置座標 $(p1_x, p1_y, \dots, p22_x, p22_y)$, 身体の角度 $(p1_{angle}, \dots, p22_{angle})$ を 1 フレームを表す数値データとして用いることにする.

4.2.2 時系列データ (本研究)

数値データを扱う RNN の実験設定を Table 1 に示す. 入力データは, ボールの座標 (b_x, b_y) , 22 体のプレイヤーの位置座標 $(p1_x, p1_y, \dots, p22_x, p22_y)$, 身体の角度 $(p1_{angle}, \dots, p22_{angle})$ の 68 入力, ボールの座標 (b_x, b_y) , 22 体のプレイヤーの位置座標 $(p1_x, p1_y, \dots, p22_x, p22_y)$ の 46 入力, ボールの座標 (b_x, b_y) の 2 入力の計 3 パターンを試す. RNN に複数フレーム分のデータを入力として与える. この時, 与えるフレーム数を時系列長とする. 例えば, 時系列長 30, フレーム間隔 1 サイクルで 1000 サイクル時点の評価予測を行う場合, 971 ~ 1000 サイクルの 30 フレーム分のデータを入力として使用する. 実験では, 時系列長 5, 8, 10, 15, 20, 30 を試す.

表 1: Experimental settings.

Dimensionality of input data	68 inputs (Ball pos, Player pos, Player angle)
	46 inputs (Ball pos, Player pos)
	2 inputs (Ball pos)
Output data	<i>Situation Score</i>
# of units	128, 256, 512, 1024
Sequence length	5, 8, 10, 15, 20, 30
Batch size	256, 512
Frame interval	1, 3, 5

4.3 実験結果

4.3.1 単一局面情報 (先行研究)

数値データを扱う FCNN, 画像データを扱う CNN のテストデータに対する実験結果を Table 2 に示す.

表 2: Experimental results (single frame).

Method	Input data	MAE
FCNN	Numeric	15.07
CNN	Image	14.00

4.3.2 時系列データ (本研究)

実験の結果を Table 3 に示す. また, 過去 30 フレームの範囲でデータを与える際に, 与えるフレーム間隔を 1, 3,

5 サイクルと変えた際の実験結果を Table 4 に示す。実験結果から、時系列データを扱うことによる *Situation Score* の予測精度が向上したとは言えない。また、入力の次元数やフレーム間隔によって精度に差が生じることが分かる。

表 3: Experimental results (time series data).

Input data	# of units	Sequence length	Batch size	MAE
68 inputs	256	10	512	15.32
46 inputs	256	10	512	15.42
2 inputs	256	10	512	15.78
68 inputs	256	20	512	15.36
46 inputs	256	20	512	15.57
2 inputs	256	20	512	16.66
68 inputs	256	30	512	15.46
46 inputs	256	30	512	15.84
2 inputs	256	30	512	16.06

表 4: Experimental results with various frame intervals.

Input data	Frame interval	MAE
68 inputs	1	15.46
46 inputs	1	15.84
2 inputs	1	16.06
68 inputs	3	16.19
46 inputs	3	15.29
2 inputs	3	15.74
68 inputs	5	16.08
46 inputs	5	15.02
2 inputs	5	15.72

4.4 考察

複数フレームを時系列データとして用いることで精度の向上を期待したが、精度の向上を確認できなかった。複数フレームにインターセプトされた場面などが含まれた場合に予測が難しくなることが原因として考えられる。インターセプトを含まないデータセットに対する精度の調査を今後の課題とする。

Table 3 より、入力に関して、ボールの位置情報のみを用いるよりもプレイヤー情報を加えたほうが精度が良かった。これはボールの位置だけでは、*Situation Score* が 0 付近の時に予測が難しいことが原因として挙げられる。Figure 6 にテストデータに含まれる各ボール位置における *Situation Score* を示す。75 から 100 に近い *Situation Score* は右ゴールに近い位置に、-75 から -100 に近い *Situation Score* は左ゴールに近い位置にそれぞれプロットされているのに対して、-50 から 50 の *Situation Score* は全フィールドに跨ってプロットされていることが確認できる。つまり、-50 から 50 の

Situation Score に対するボール位置のみを用いた評価予測は難しいことが視覚的に分かる。

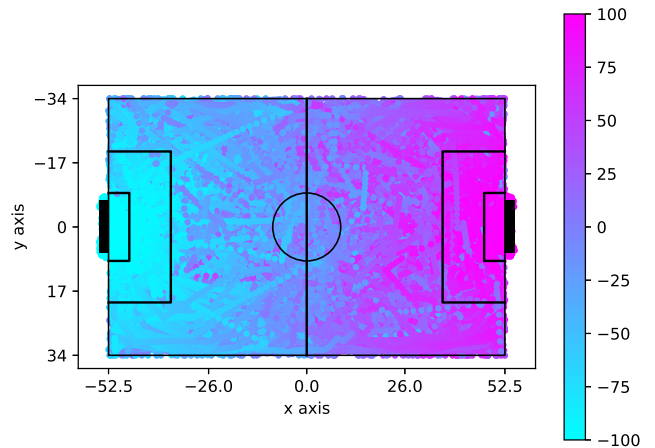


図 6: *Situation Score* map in the soccer field.

Figure 7 に RNN (2 inputs) , Figure 8 に RNN (46 inputs) を用いた際の各 *Situation Score* の MAE をそれぞれ示す。それぞれの図を比較すると、-25 から -75, 25 から 75 あたりにかけて、46 inputs の方が MAE が小さい。つまり、2 inputs のようにボールの位置だけではゴールに近い場合 (*Situation Score* が 100 または -100 に近い場合) は高い精度の予測ができるが、その他の場面においてはプレイヤーの位置情報を用いたほうが精度が良い。これより、プレイヤー情報は特に *Situation Score* が ± 50 前後の局面評価において重要な要素であることが言える。




図 7: MAE of RNN (2 inputs) model's prediction in each *Situation Score*.

また、Table 4 より、入力に与えるフレーム間隔が 1 サイクルではフレーム間で特に位置情報の変化がないため、1 サイクルで大きく変化する Player angle を加えた時 (68 inputs) のほうが精度が高くなったと考えられる。フレー




図 8: MAE of RNN (46 inputs) model's prediction in each *Situation Score*.

ム間隔について、1 サイクルよりも間隔を 3 サイクル、5 サイクルと空けたほうが位置情報に変化が生まれるため、プレイヤー位置情報を用いた時 (46 inputs) に MAE が低く、精度が良くなったと考えられる。しかし、フレーム間隔を空けた際には、1 サイクルでも大きく変化する Player angle を加える (68 inputs) と、ノイズとなり誤差が大きくなったと考察する。

5 おわりに

試合状況を定量的に評価することで、優勢度を正確に把握することができる。これにより、実践においては試合状況の評価からチームの戦術切替への応用、また、スポーツの中継などにおいて、音声や環境音と連携することで自動実況の実現可能であると考えられる。

本論文では、単一局面情報だけではなく時系列データを用いた RNN による試合状況の定量的な評価を実現した。しかし、時系列データを用いることによる精度の向上は見られなかった。

今後の課題として、インターセプトを除いたデータセットでの実験、未知チーム間の試合に対する試合状況の評価性能の調査、複数フレームを入力として与えた FCNN との比較実験による RNN の有効性の調査、画像データを時系列的に扱うことができる Convolutional LSTM [8] や複数フレームの画像を扱う 3D-CNN [9] を用いた実験が挙げられる。

参考文献

- [1] Hitoaki Kitano, Minoru Asada, Yasuo Kuniyoshi, Itsuki Noda, Eiichi Osawa and Hitoshi Matsubara, "RoboCup: A Challenge Problem for AI", *AI Magazine*, Vol.18, No.1, pp.73–85, 1997.
- [2] Tomoharu Nakashima and Tanguy Pomas, "Evaluation of Situation in RoboCup 2D Simulations using Soccer Field Images", *Proc. of the RoboCup Symposium*, 12 pages, 2018.
- [3] Tomoharu Nakashima, Satoshi Mifune, Jordan Henrio, Oliver Obst, Peter Wang and Mikhail Prokopenko, "Kick Extraction for Reducing Uncertainty in RoboCup Logs", *Proc. of the 17th International Conference on Human Interface and the Management of Information*, pp.622–633, 2015.
- [4] Aida Khosroshahi, Eshed Ohn-Bar and Mohan Manubhai Trivedi, "Surround Vehicles Trajectory Analysis with Recurrent Neural Networks", *Proc. of the IEEE 19th Conference on Intelligent Transportation Systems (ITSC)*, pp.2267–2271, 2016.
- [5] Edward Choi, Mohammad Taha Bahadori, Andy Schuetz, Walter F. Stewart and Jimeng Sun, "Doctor AI: Predicting Clinical Events via Recurrent Neural Networks", *Proc. of the Machine Learning for Healthcare 2016*, pp.301-318, 2016.
- [6] Zhiyuan Shi, Min Xu, Quan Pan, Bing Yan and Haimin Zhang, "LSTM-based Flight Trajectory Prediction", *Proc. of the 2018 International Joint Conference on Neural Networks (IJCNN)*, pp.1–8, 2018.
- [7] Alexandre Alahi, Kratarth Goel, Vignesh Ramanathan, Alexandre Robicquet, Li Fei-Fei and Silvio Savarese, "Social LSTM : Human Trajectory Prediction in Crowded Space", *Proc. of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.961–971, 2016.
- [8] Xingjian Shi, Zhoung Chen, Hao Wang, Dit-Yan Yeung, Wai-Kin Wong and Wang-chun Woo, "Convolutional LSTM network: A machine learning approach for precipitation nowcasting", *Proc. of the Advances in neural information processing systems*, pp.802–810, 2015.
- [9] Xiaojie Huang, Junjie Shan and Vivek Vaidya, "Lung nodule detection in CT using 3D convolutional neural networks", *Proc. of the IEEE 14th International Symposium on Biomedical Imaging (ISBI)*, pp.379–383, 2017.