

RoboCup サッカーにおける敵位置情報に基づいた敵フォーメーション同定

Opponent's Formation Identification based on Position Information for RoboCup Soccer

福島 卓弥 †, 中島 智晴 †, 秋山 英久 ‡

Takuya FUKUSHIMA†, Tomoharu NAKASHIMA†, Hidehisa AKIYAMA‡

大阪府立大学 †, 福岡大学 ‡

Osaka Prefecture University†, Fukuoka University‡

takuya.fukushima@edu.osakafu-u.ac.jp

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

akym@fukuoka-u.ac.jp

Abstract

The aim of this paper is to propose a method for identifying the opponent formation type in an online manner during a game. To do so, opponent teams were clustered according to the position of their players. Each cluster is investigated to determine the difficulty for our team to defeat such a strategy. Then, an identification model is used online to determine if the opponent team adopts such a strategy or not. Furthermore, we also investigate how quickly the opponent formation can be identified. Through a series of computational experiments, it is shown that the model can identify opponent formation type quickly and accurately. Therefore, we show the effectiveness of the identification model to switch our strategy.

1 はじめに

ロボット工学と人工知能の領域横断型研究プロジェクトとしてRoboCup [1] が知られている。RoboCup には様々なリーグが存在しており、それぞれのリーグにおいて活発に研究、開発が行われている。その中の一つであるRoboCup サッカーリーグでは、ただ単に勝利するだけでなく、賢く安定して勝利することが望まれている。ランダムや思いつきで作られた戦術を使って勝利するよりも、緻密なデータ分析や機械学習によるモデル化を活用して勝利につながる戦術を生成することがRoboCup の理念と合致する。パスやドリブル等の行動を洗練する [2, 3], 相手の行動を予測して意思決定を行う [4], 相手チームに合わせた戦術をとる [5, 6], といった研究が様々な観点から進められている [7].

現在、サッカーシミュレーション 2D リーグでは、毎年各チームが変化を加えることにより、多種多様な戦術が存在している。戦術には相性があるため、1つの戦術で全てのチームに勝つことは困難である。そのため、安定した勝利には、相手チームに対して相性の良い戦術をとることが有効である。有効な戦術を選択するためには、自チームが複数の戦術を用意し、相手チームの戦術を見極め、それに応じて自チームの戦術を切り替える必要がある。相手チームの戦術を素早く見極め戦術を切り替えることで、試合を有利に進めることが可能になる。

本論文では、相手チームの戦術を見極める手法に焦点をあてる。本研究の目的は、自チームの戦術が相手チームと相性が悪いかどうかを判断することである。相手チームとの相性を調べるためには、相手チームを分析しなければならない。相手チームの戦術や行動をモデル化し識別する研究は進められている [8] が、オフラインでの識別に用いられている。相手チームの戦術は試合が始まるまで分からないため、試合中にオンラインで判断することが求められる。そこで本論文では、オンラインで戦術を切り替えるために、戦術はプレイヤーのポジショニングによって表現されるものと仮定し、敵位置情報に着目する。まず、敵位置情報に基づいて相手チームのクラスタリングを行い、自チームが不得意とするフォーメーションを調査する。次に、相手チームが不得意なフォーメーションであるかどうかをオンラインで判断するため、識別モデルを構築する。識別モデルの実際の試合における有効性を示すため、経過時間と識別率の関係を検証する。

2 RoboCup

2.1 RoboCup サッカーシミュレーション 2D リーグ

本研究では、RoboCup サッカーシミュレーション 2D リーグを対象とする。シミュレーションリーグはRoboCup 創設当初から存在する最も古いリーグの1つである。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。また、プレイヤー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。2Dリーグでは、kick, dash, turn などの抽象化されたコマンドを基本行動とする。図 1 に 2D リーグの試合の様子を示す。試合は前後半 3000 サイクルずつ合計 6000 サイクルからなる。1 サイクルは 0.1 秒で離散化されている。

プレイヤーやコーチは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いる。各プレイヤーには実際の間人と同様に視野が設定されており、自身の視野内で認識できた情報に基づき、視覚情報が形成される。また、他のプレイヤーやコーチがメッセージとして発している情報を聴覚情報として使用できる。これらの視覚情報や聴覚情報からフィールド情報を形成し、これに基づきドリブルやパスなどの意思決定を下す。しかし、視覚情報にはノイズが含まれ、正確な情報を獲得することができない。聴覚情報についても確実に受信できるわけではなく、コーチのメッセージは通常プレイ時には到達までに遅延も発生する。そのため、プレイヤーはフィールド上の正確な情報を保持することはできない。一方で、コーチはフィールド上のすべての情報をノイズなしで取得することができるため、正確なフィールド情報を保持することができる。通常プレイ時におけるプレイヤーへの意思伝達には遅延が発生し、回数も制限されているが、ハーフタイム時においては、プレイヤーに即時に情報を伝達することが可能である。

また、試合毎に異なる能力を持つプレイヤーのセットが与えられ、各チームがポジションの割当を行う。このようにランダムな要素が多く、プレイヤーが獲得する情報や物体の移動にノイズがかかることから、同一の対戦相手であっても、試合毎に結果や内容が異なる。

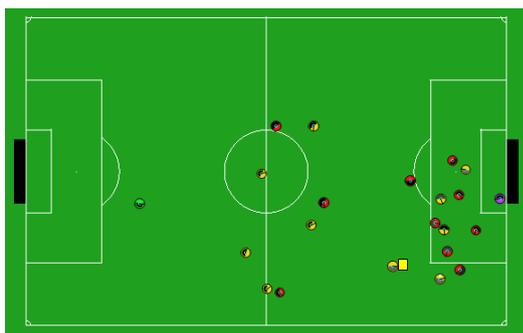


図 1: Soccer simulation 2D league

2.2 試合ログ

試合ログは、RoboCup サッカーシミュレーション 2D リーグにおいて、試合終了後にサーバから出力されるファイルである。試合ログには、各プレイヤーの最高速度やキックできる範囲等といったパラメータ、ゲームの状態、サイク

```
(player_type (id 17)(player_speed_max 1.05)(stamina_inc_max 51.6181)
(player_decay 0.459447)(inertia_moment 6.48617)(dash_power_rate 0.00489698)
(player_size 0.3)(kickable_margin 0.643989)(kick_rand 0.0439887)(extra_stamina
85.5322)(effort_max 0.857871)(effort_min 0.457871)(kick_power_rate 0.027)
(foul_detect_probability 0.5)(catchable_area_1_stretch 1.03085))
(playmode 1 kick_off_1)
(team 1 opuSCOM NEO_FS 0 0)
(show 1 ((b) 0 0 0 0) ((l 1) 0 0x9 -49.1109 0.0076 -0.0444 0.003 -92.301 90 (v h
180) (s 8000 1 1 130555) (c 0 1 69 0 1 71 1 1 0 0 1)) ((l 2) 11 0x1 -18 -5 0 0 7.368
-3 (v h 180) (s 8000 0.941673 1 130600) (f 1 11) (c 0 0 50 0 1 51 1 0 0 0 1)) ((l 3) 8
0x1 -18 5 0 0 -38.621 26 (v h 180) (s 8000 0.805717 1 130600) (f 1 11) (c 0 0 50 0
1 51 1 0 0 0 1)) ((l 4) 7 0x1 -18 -14 0 0 -5.5 7 (v h 180) (s 8000 0.944233 1 130600)
(f 1 11) (c 0 0 50 0 1 51 1 0 0 0 1)) ((l 5) 16 0x1 -18 14 0 0 7.083 2 (v h 180) (s 8000
0.876201 1 130600) (f 1 11) (c 0 0 50 0 1 51 1 0 0 0 1)) ((l 6) 4 0x1 -15 0 0 0 29.599
1 (v h 180) (s 8000 0.996398 1 130600) (f 1 11) (c 0 0 50 0 1 51 1 0 0 0 1))
```

図 2: Game log

ル毎のプレイヤーとボールの位置や速度の情報、プレイヤーの行動、プレイヤーやコーチ間の情報の伝達等といった試合中の全ての情報が含まれている。そのため、試合ログを用いることで終了した試合を再生することができる。実際の試合ログを図 2 に示す。図 2 のように、試合ログは試合中の情報が文字列で表現されている。そのため、分析に用いる際は必要な情報のみを抽出する。

2.3 関連研究

RoboCup サッカーシミュレーション 2D リーグでは、戦術やポジショニング、相手チームの分析に関する様々な研究が行われている [8]。相手チームの分析に関する研究は、フィールド上のすべての情報をノイズなしで取得できるコーチエージェントを用いて行われる場合が一般的である。その一例として、Gregory ら [9] は決定木を用いて、プレイヤーに攻撃や守備のアドバイスをを行うコーチを開発した。また Ramin ら [10] はルールを用いたエキスパートシステムと決定木を用いたコーチ開発の研究を行った。Mazda ら [11] もまた、敵の行動予測のモデル化を研究した。戦術を表現するために、ポジショニングに着目した手法が幾つか提案されている。例えば、Luis ら [12] は自チームの戦術に応じてポジショニングを変更する手法を提案している。また Akiyama ら [13] は、Delaunay Triangulation を用いたボール位置に基づくプレイヤーのポジショニング手法を提案している。相手チームの戦術分析に関して、例えば Riley ら [14] は、敵プレイヤーのポジションやパス、ドリブルを記録することにより、相手チームを識別する手法を提案した。また、三船ら [5] は、キック情報に着目して戦術切り替えを行う手法を提案した。Visser ら [15] はフォーメーションを識別する研究を行った。しかしながら、相手チームの戦術を素早く確実に判断することはできていない。そのため、試合中に戦術を切り替えるためには、精度が高く、高速で判断可能な手法が必要である。

3 フォーメーション同定

本研究では、戦術はプレイヤーのポジショニングにより表現されるものと仮定する。相手チームの戦術を見極めるに

は、フォーメーションの特徴を正しく捉える必要がある。本章では、まず敵フォーメーション同定の概要を説明し、次に識別に用いる手法について以下に説明する。

3.1 敵位置情報に基づいたデータ抽出

敵のフォーメーションを数値表現するため、図 3 のようにサッカーフィールドをグリッド状に分割する。1 サイクル毎に各グリッド内に存在する敵プレイヤーの人数を計算する。各グリッド毎に計算した値を積算する。この積算値を、計算に用いたサイクル数により割ることで平均値を求める。この平均値を本実験での入力データとして扱う。例えば 6×4 に分割した際は、24 次元ベクトルのデータが計算される。

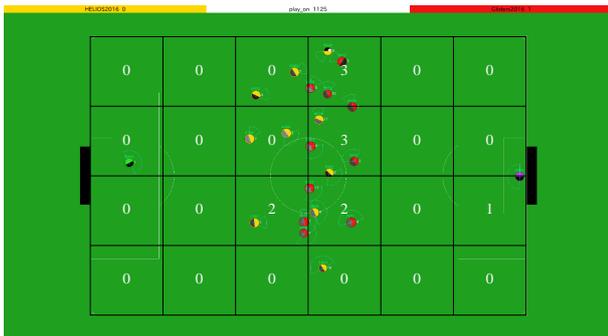


図 3: Discretization of the soccer field by a grid of size 6×4 .

3.2 フォーメーションの識別モデル

フォーメーションを識別するためのモデルを構築する。識別モデルによる有効性を調査するため、複数の機械学習手法によりモデルを構築する。モデルの構築には、ニューラルネットワーク (NN)、サポートベクターマシン (SVM)、ランダムフォレスト (RF) を用いて、教師あり学習を行う。それぞれのデータに対するラベル付けは、相手チームのフォーメーションタイプによって決定する。ラベル付けの方法については??章で、教師データの作成については 4 章で後述する。

本論文では、ボールの支配時間が長いにもかかわらず得点に結びつかない場合、戦術の相性が悪いと定義し、戦術を切り替えるべきであると判断する。相手チームが戦術切り替えの対象かどうかを識別するために、試合ログから自チームのボール支配率を計算する。キックを行ったプレイヤーと、その次にキックを行ったプレイヤーが同一チームである場合、その間のサイクルはキックを行ったチームがボールを支配しているものとする。不得意度を表す指標を、式 (1) と定義する。ここで、 k 試合目における自チームのボール支配率を $p(k)$ 、得点を $g(k)$ とおく。

$$score(k) = d(g(k)) \cdot p(k), \quad (1)$$

$$d(x) = \begin{cases} 1 & (x = 0) \\ 0 & (x \geq 1). \end{cases} \quad (2)$$

複数の試合ログから式 (1) を計算し、その平均値が閾値以上のチームを戦術切り替えの対象チームとして扱う。

3.3 敵位置情報に基づくチーム分類とラベル付け

本項では、位置情報に基づく相手チームの分類手法について説明する。相性の悪いチーム戦術における特徴的なフォーメーションタイプを調査するため、3.2 節で戦術切り替えが必要であると判断されたチームを対象に、クラスタリングを行う。本論文では、クラスタリングのために混合ガウス分布を用いる。混合ガウス分布のハイパーパラメータは EM アルゴリズムを用いて最適化する。最適クラスタ数は Calinski-Harabasz 基準値 [16] によって決定する。Calinski-Harabasz 基準値ではクラスタ内分散とクラスタ間分散の比を用いる。

3.3 節の結果から、3.1 節で先述したデータにラベル付けを行う。これを識別モデルの教師データとして扱う。また、ラベルの数は最適クラスタ数に準拠する。

4 数値実験

本論文では、実際の試合ログを用いて数値実験を行う。まず、戦術切り替えの対象であるチームのうち、特徴的なフォーメーションを分類する。次に、適切な戦術に切り替えるため、敵位置情報を用いてフォーメーションを識別する。この際、敵フォーメーションの識別に必要なサイクル数を検証するため、サイクル数による識別率の変化を調査する。また、グリッド数による識別率の変化を調査する。

4.1 フォーメーションの分類

本節では、戦術の切り替えが必要であるチームのフォーメーションを分類する。最適クラスタ数を決定することで、特徴的なフォーメーションの数を調査する。

4.1.1 実験設定

試合ログを作成するために、HELIOS [17] と CYRUS2014, InfoGraphics, HERMES2015, Gliders2016, FURY, HERMES2016, MarliK2016, Ziziphus, FRA-UNited, WrightEagle, Ri-one の 11 チームを 200 試合ずつ対戦させる。本実験では前半のみの試合ログを使用する。HELIOS は本研究室と福岡大学が共同で開発しているチームである。他のチームは RoboCup 2014-2016 に出場したチームのうち、3.2 節の手法から戦術切り替えが必要と判断したチームである。CYRUS2014, InfoGraphics は RoboCup 2014 に、HERMES2015, WrightEagle は RoboCup 2015 に出場したチームである。Gliders2016, FURY, HERMES2016, MarliK2016, Ziziphus, FRA-UNited, Ri-one は RoboCup 2016 に出

場した最新のチームである。クラスタ数を 2-10 個の間で変化させ、Calinski-Harabasz 基準値が高いクラスタ数を最適クラスタ数の候補とする。入力データとして、フィールドを 30×20 のグリッド状に分割したものを利用して、データを作成する。

4.1.2 実験結果

実験結果を図 4 に示す。図 4 から最適クラスタ数の候補として 3 または 4 が考えられる。クラスタ数を 3 としたとき、図 5 上図のようにゴール前に全てのプレイヤーを集める守備を偏重したチーム (CYRUS2014, HERMES2015, FURY, Ziziphus) と、図 5 下図のように一直線状に並びスルーパスを防ぐようなフォーメーションのチーム (InfoGraphics), その他のチームという 3 種類に分類された。クラスタ数を 4 としたときは、クラスタ数 3 の結果に加えて、同様に一直線状に並ぶチームが新たなクラスタとして選出された (Gliders2016)。InfoGraphics と Gliders2016 の違いとして、Gliders2016 はボールを保持すると攻撃的になるのに対し、InfoGraphics はボールを保持しても攻めてこないことが考えられる。そのため、InfoGraphics と Gliders2016 を同じフォーメーションとして扱い、最適クラスタ数は 3 とする。以降、図 5 上図のようなフォーメーションのチームを “wall”, 図 5 下図のようなフォーメーションのチームを “line”, そうでないチームを “normal” と呼ぶことにする。

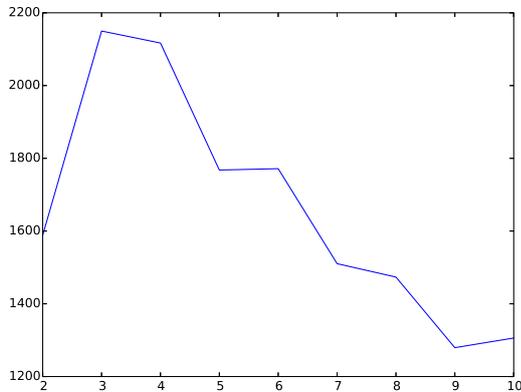


図 4: Variation of the Calinsky-Harabasz index according to the number of clusters.

4.2 フォーメーション識別

本節では、実験 4.1 の結果を踏まえ、敵位置情報に基づきフォーメーション識別を行う。オンラインでの判断への有効性を示すため、経過時間と識別率の関係性を検証する。また、グリッド数による識別率の変化を調査する。

4.2.1 実験設定

実験 4.1 の結果を踏まえ、wall, line, normal の 3 クラス識別を行う。フィールドを 6×4 , 12×8 , 15×10 ,

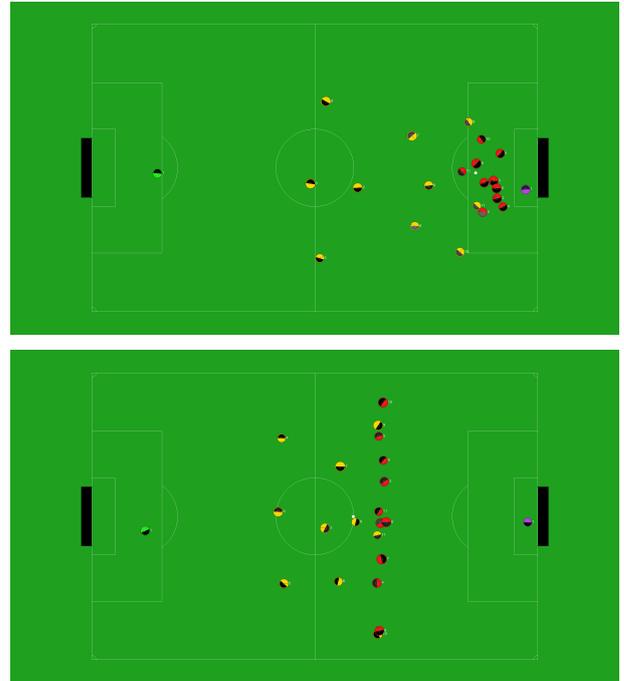


図 5: Typical defensive formations. Top: “wall”, bottom: “line”.

24×16 , 30×20 の 5 種類のグリッド状に分割し、教師データを作成する。HELIOS と RoboCup 2016 に出場した全てのチーム, CYRUS2014, InfoGraphics, HERMES2015, WrightEagle の 19 チームを対戦させ、前半のみの試合ログを作成する。4.1.1 項の際と同様に、CYRUS2014, InfoGraphics は RoboCup 2014 に出場したチームであり、HERMES2015, WrightEagle は RoboCup2015 に出場したチームである。wall のチームのうち、CYRUS2014 と FURY は得失点差によって戦術を変更する。そのため、この 2 チームに対しては自チームが無得点である場合のみのデータを用いる。それぞれのクラスに対して、約 3000 個のログから位置情報を抽出し、教師データとして扱う。データのラベル付けは 4.1 節の結果に従う。ラベル付けの一覧を表 1 に示す。識別器として NN, SVM, RF を用いる。識別器のパラメータは予備実験の結果から表 2 のように設定する。

表 1: Opponent teams’ formation labels

Opponent Team	label
CYRUS2014	wall
HERMES2015	wall
FURY	wall
Ziziphus	wall
InfoGraphics	line
Gliders2016	line
others	normal

表 2: Hyper-parameters used for the classifiers

Classifier	Parameter	Setting
NN	Activation function	Logistic function
	Optimization algorithm	L-BFGS method
	Structure	3 layers
	The number of neurons in Input layer	The number of grid
	The number of neurons in Output layer	3 neurons
	L2 penalty	0.0001
	Tolerance	0.0001
SVM	Kernel	Linear
	Penalty	1.0
	Tolerance	0.0001
RF	Criterion	Gini index
	The number of trees	10
	Sampling	Bootstrap

4.2.2 実験結果

実験結果を図 6-10 に示す。図 6-10 それぞれは、フィールドを 6×4 , 12×8 , 15×10 , 24×16 , 30×20 に分割した場合の実験結果を表している。どのグリッド数においても 1500 サイクル付近から、収束していることが分かる。サイクル数が十分多いとき、識別器による識別率の違いはあまり見られない。NN と SVM については、グリッド数に比例し、少ないサイクル数での識別率が高い。このことから、グリッド数が多ければ、より早い段階で識別が可能であることが分かる。また、RF と比較して NN と SVM は収束に必要なサイクル数が少ないことが分かる。一方、RF ではサイクル数が少ない場合、NN, SVM と比較して識別能力が低い。このことから、RF を使用するにはある程度のデータ量が必要であると考えられる。

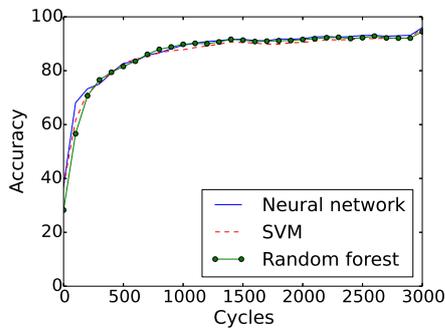


図 6: Accuracy rates of the three models according to field discretized with a grid of size 6×4

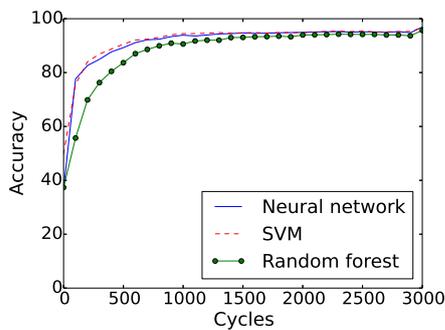


図 7: Accuracy rates of the three models according to field discretized with a grid of size 12×8

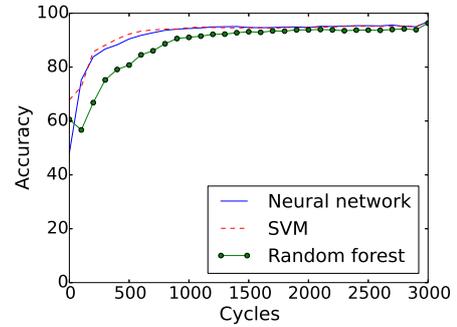


図 8: Accuracy rates of the three models according to field discretized with a grid of size 15×10

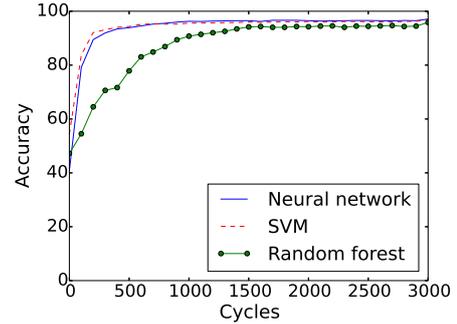


図 9: Accuracy rates of the three models according to field discretized with a grid of size 24×16

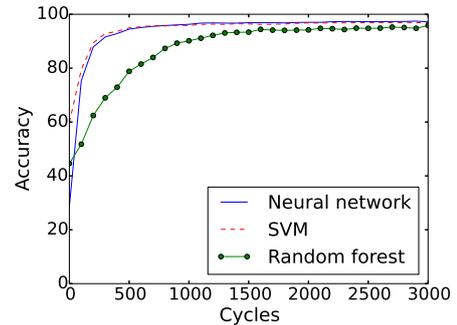


図 10: Accuracy rates of the three models according to field discretized with a grid of size 30×20

5 おわりに

本論文では、敵の戦術を見極めるために、位置情報を用いてオンラインで戦術を判断する手法を提案した。敵の戦略を見極めることができれば、それに応じて自チームの戦術を切り替えることができる。そのために、敵フォーメーションを同定しラベル付けを行い、機械学習手法を用いて識別モデルを構築した。今後の課題として、未知のチームに対する識別率の調査や、オンライン識別器の実装などがあげられる。

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] Luiz A. Celiberto Jr., Carlos H. C. Ribeiro, Anna Helena Reali Costa, and Reinaldo A. C. Bianchi. “Heuristic Reinforcement Learning applied to RoboCup Simulation Agents,” *Proc. of the 11th RoboCup Symposium*, pp. 220-227, 2007.
- [3] Aijun Bai, Feng Wu, and Xiaoping Chen. “Towards a Principled Solution to Simulated Robot Soccer,” *Proc. of the 16th RoboCup Symposium*, pp. 141-153, 2012.
- [4] Thomas Gabel, Martin Riedmiller and Florian Trost. “A Case Study on Improving Defense Behavior in Soccer Simulation 2D: The NeuroHassle Approach,” *Proc. of the 12th RoboCup Symposium*, pp 61-72, 2008.
- [5] 三船 哲史, 中島 智晴, 秋山 英久, “RoboCup サッカーにおけるキック分布を用いたゲーム戦術の切り替え,” *Proc. of the 44th Meeting of Special Interest Group on AI Challenges*, pp. 1-6, 2016.
- [6] Jordan Henrio, Thomas Henn, Tomoharu Nakashima, and Hidehisa Akiyama, “Selecting the Best Player Formation for Corner-Kick Situations Based on Bayes’ Estimation.” *Proc. of the 20th RoboCup Symposium*, 12 pages, 2016.
- [7] 秋山 英久, “ロボカップサッカー シミュレーション 2D リーグ必勝ガイド,” 秀和システム, 2006.
- [8] Shokkofeh Pourmehr, Chitra Dadkhah, “An Overview on Opponent Modeling in RoboCup Soccer Simulation 2D,” *Proc. of the 15th RoboCup Symposium*, pp. 402-414, 2011.
- [9] Gregory Kuhlmann, Peter Stone, and Justin Lallinger, “The UT Austin Villa 2003 Champion Simulator Coach: A Machine Learning Approach,” *RoboCup 2004: RoboCup 2004: Robot Soccer World Cup VIII* pp. 636-644, 2005.
- [10] Ramin Fathzadeh, Vahid Mokhtari, Morteza Mousakhani, and Alizera Mohammad Shahri, “Coaching with Expert System Towards RoboCup Soccer Coach Simulation,” *Proc. of the 10th RoboCup Symposium*, pp. 488-495, 2006.
- [11] Mazda Ahmadi, Abolfazl Keighobadi Lamjiri, Mayssam M. Nevisi, Jafar Habibi, and Kambiz Badie, “Using a Two-Layered Case-Based Reasoning for Prediction in Soccer Coach,” *Proc. of the International Conference on Machine Learning; Models, Technologies and Applications. MLMTA ’03*, pp. 181-185, 2003.
- [12] Luis Paulo Reis, Nuno Lau and Eugenio Oliveira, “Situation Based Strategic Positioning for Coordinating a Simulated RoboSoccer Team,” *Balancing Reactivity and Social Deliberation in MAS*, Vol. 2103, pp. 175-197. 2001.
- [13] Hidehisa Akiyama, Itsuki Noda, “Multi-Agent Positioning Mechanism in the Dynamic Environment,” *Proc. of the 12th RoboCup Symposium* , pp. 377-384, 2008.
- [14] Patrick Riley, Manuela Veloso, “On Behavior Classification in Adversarial Environments,” *Proc. of the 5th Distributed Autonomous Robotic Systems (DARS 2000)*, pp. 371-380, 2000.
- [15] Ubbo Visser, Christian Drücker, Sebastian Hübner, Esko Schmidt, and Hans-Georg Weland, “Recognizing formations in opponent teams,” *RoboCup 2000: Robot Soccer World Cup IV*, pp. 391-396, 2001.
- [16] Calinski, T., and J. Harabasz, “A dendrite method for cluster analysis,” *Communications in Statistics*, Vol. 3, No. 1, pp. 1-27, 1974.
- [17] Hidehisa Akiyama, Tomoharu Nakashima, Jordan Henrio, Thomas Henn, Sho Tanaka, Tomonari Nakade, Takuya Fukushima, “HELIOS2016: Team Description Paper,” *RoboCup2016 Leipzig, Germany*, 6 pages, 2016.