

Прогнозирование текущей стратегии противника в виртуальном футболе на основе местоположения игроков

Д. А. Петруненко

Санкт-Петербургский государственный
электротехнический университет
«ЛЭТИ» им. В.И. Ульянова (Ленина)

nokiad_1999@mail.ru

С. А. Беляев

Санкт-Петербургский государственный
электротехнический университет
«ЛЭТИ» им. В.И. Ульянова (Ленина)

bserge@bk.ru

Аннотация. В статье решается задача прогнозирования траекторий движения противника на текущем такте игры в виртуальном футболе Soccer Simulation. Представленное решение определения стратегии противника, основано на моделях нейронной сети по аналогии с Opponent Formation Identification Based on Position Information. В основе лежит метод, при котором поле разделяется на несколько областей, и в качестве исходных данных для нейронной сети подаётся количество игроков своей и чужой команды в каждой из областей. В представленное решение входит описание перечня анализируемых стратегий, атакующих и защитных, описание собранных данных при обработке нескольких игр, предобработка данных для обучения модели, формирование нескольких конфигураций моделей нейронной сети, их сравнение друг с другом и с существующими аналогами. Полученные результаты позволяют определять текущую стратегию противника для различных построений противника. Полученное решение по точности не хуже своих аналогов по определению стратегий в виртуальном футболе. Максимальная точность получена при использовании метода обучения «без учителя». Обученные модели могут применяться совместно с системами принятия решений.

Ключевые слова: интеллектуальные агенты, виртуальный футбол, мультиагентные системы, прогнозирование, машинное обучение в виртуальном футболе

I. ВВЕДЕНИЕ

Современные исследования в области искусственного интеллекта проводят с использованием таких платформ как RoboCup 2D Soccer Simulation League Champion [1], RoboCup Rescue Simulation [2] и др. Среда виртуального футбола Soccer Simulation [3] максимально приближена к реальному миру и обеспечивает реалистичность за счёт высокой динамичности, неопределённости восприятия и действий, вычислительных ограничений. Она используется для различных исследований мультиагентных систем, подразумевает прогнозирование как действий игроков своей команды, так и противника. Умение предсказать будущие действия позволяет оценить вероятную стратегию и тактику противника. Возможные подходы – это анализ действий команд на протяжении ряда игр [4], анализ действий на текущем такте игры [5] текущим игроком [6, 7, 10] или агентом-

тренером, который оценивает ситуацию на поле и предлагает игрокам стратегию противодействия [8, 9, 11]. Учёт нескольких предыдущих тактов игры и прогнозирование будущих местоположений и действий противника позволяют обогатить модель текущего состояния мира.

В виртуальном футболе при прогнозировании действий оценивают удары по воротам, передачи, перехват мяча и ведение мяча. Это можно сделать различными методами: используя текущее местоположение агентов и статические объекты поля, навигацией по ближайшим флагам и дальней линии [12], вероятностными предположениями с уточнением методом фильтра частиц [12, 13] и на основе случайных конечных множеств (метод RFS) [14]. Перечисленные методы используют данные только о видимых объектах, но есть исследования, учитывающие игроков, которые недавно исчезли из поля зрения [15], в том числе с помощью фильтра Калмана [12, 13, 16]. Задача усложняется ещё и тем, что игроку неизвестны его собственные координаты, которые необходимо вычислять на основе поступающей информации о видимых флагах и линиях виртуального поля.

II. ВОЗМОЖНЫЕ СПОСОБЫ РЕШЕНИЯ ЗАДАЧИ

Исследования проводятся в течение нескольких лет, рассмотрим существующие методы решения задачи прогнозирования действий игроков в виртуальном футболе. Критерии отбора:

- оценка ситуации – объём обрабатываемых данных, который используется для дальнейшего принятия решения. Приоритетной является оценка «полной» ситуации, с использованием информации обо всех объектах на поле и их предыдущих состояниях;
- прогнозирование – возможность выполнения прогнозирования местоположения, будущих действий, возможных перестроений или стратегий противника;
- точность – полнота соответствия действий противника его реальным будущим действиям.

Представленные далее методы выбирались, исходя из данных критериев.

A. Моделирование функций оценки с использованием нейронных сетей

Модель осуществляет выбор дальнейших действий на основе дерева решений. Переход по дереву осуществляется с учётом весов дуг, чем больше вес, тем предпочтительнее соответствующее действие. Для формирования оценки весов используются нейронные сети. Прогнозирование осуществляется на основе поиска похожих последовательностей действий и оценке последующих действий [4]. Планирование действий основывается не на текущем поведении противников, а на уже отработанных моделях игр.

B. Модель командного поведения агентов на основе когнитивного подхода

Модель основывается на исследовании поведения игроков в малых группах и их взаимодействия. Принятие решений производится на основе оценки функции полезности агентов и когнитивного диссонанса. В анализ когнитивного диссонанса включаются два фактора: количество забитых агентом голов, количеством сделанных пасов. Если значение функции полезности выше и когнитивный диссонанс близок к нулю, то действие будет выполнено [5]. Прогнозирование действий противника не выполняется.

C. Распознавание формирования противника на основе информации о позиции в условиях реального времени

Модель позволяет определять стратегию игры противников в режиме реального времени, основываясь на положении противников. Классификаторы для модели получены с использованием нейронных сетей, машины опорных векторов и случайного леса. Входными данными для обучения служат вектора. Входной вектор строится делением поля на равные квадратные участки, в которых учитывается количество агентов противника и их порядковые номера. Затем выполняется подсчёт количества игроков на каждом выделенном участке [9].

D. Функция оценки обучения для футбольного симулятора RoboCup на основании человеческого выбора

Модель осуществляет выбор дальнейших действий на основании дерева решений. Путь от корневого узла к ветви представляет собой одну из последовательностей действий. Сгенерированные последовательности действий ранжируются на основе значения оценки, и в конечном итоге выбирается последовательность действий, имеющая наибольшее значение оценки [7].

E. Распознавание построений команд в многоагентных системах

Модель основывается на оценке формации команды противника с помощью нейронной сети. При этом используется «тренер» (отдельно выделенный член команды, который наблюдает за всем игровым полем). Он определяет формацию с помощью нейронной сети, затем в любые состояния отличные от состояния «PLAY ON», генерирует сообщения для своей команды, в которых информирует о текущей тактике противника [6, 8].

F. Распознавание вероятностных моделей передвижения противника

Модель использует оконный подход для извлечения значений функции полезности и дерева решений для классификации. От размера окна зависит точность классификации. На протяжении всей игры продолжается улучшение предсказания [6, 9]. Не оценивает положение союзников, что не позволяет на её основе кооперироваться и оценивать стратегию противников, точность определения может достигать 94 % за 9 наблюдаемых тактов.

G. Представление данных в виде графа для анализа многоагентных пространственно-временных спортивных данных

Модель основывается на оценке формации команды противника с помощью графовых нейронных сетей. Воспринимаемая игроком информация о мире представляется в виде графа, где игроки и атрибуты, связанные с игроками, моделируются как узлы графа, а их взаимодействия – как взвешенные ребра. Из такого представления в дальнейшем с помощью графовой нейронной сети выполняется прогнозирование возможных действий агентов [10]. Не учитывает данные о предыдущих тактах игры.

H. Роль вознаграждения в формировании поведения нескольких футбольных агентов: эмпирическое исследование

Модель выполняет принятие решений, учитывая предыдущий опыт, с помощью обучения с подкреплением. Скалярное вознаграждение формирует поведение агента, предоставляя сигнал, который агент может использовать для оценки ценности действий. Причём в процессе обучения каждый агент использует для обучения данные от всех агентов, а в процессе игры решения принимаются самостоятельно [11].

I. Вывод

Модели Online Opponent Formation Identification Based on Position Information и Learning Evaluation Function for RoboCup Soccer Simulation using Humans' Choice соответствуют всем заданным параметрам, но их применение зависит от задачи и доступных данных, точности определения в среднем достигают 93-95% и 90-93% соответственно. В контексте текущей задачи модель будет основываться на модели Opponent Formation Identification Based on Position Information.

III. ПРЕДЛАГАЕМОЕ РЕШЕНИЕ

Для выполнения определения стратегии противников выполняется процедура определения местоположения динамических объектов на поле. Получение местоположения описано в [15]. После получения местоположения поле разбивается на квадратные области по аналогии с [9]. Затем объекты разделяются по областям, в которых они находятся. На выходе получаются два вектора распределения, их размерность соответствует количеству областей, значения – количеству объектов в каждой области. В одном из векторов хранятся распределения игроков союзной команды, во втором распределение противников. Эти данные подаются на вход нейронной сети для

определения стратегии. В качестве прототипа использована конфигурация нейронной сети в [9].

А. Набор данных

Данные для экспериментов взяты в [17]. Результатом обработки и разметки данных стал набор данных из 3000 записей, содержащих 4 вида стратегий противника. Две атакующие (атака центра поля и атака вблизи ворот) и две защитные стратегии (защита центра поля и защита ворот). Каждая запись в наборе данных для видимых игроков состоит из двух векторов противников и союзников, их размерность зависит от размерности входного слоя нейронной сети, вычисленных текущим игроком своего местоположения, название своей команды. В дальнейшем вектора дополняются игроками, которые недавно исчезли из поля зрения.

В. Набор данных

Предобработка данных представлена в двух вариантах. В первом варианте набор данных вручную разделялся на стратегии для дальнейшего обучения сети методами «обучения с учителем». Второй вариант подразумевал разделение данных для дальнейшего «обучения без учителя». Данные сжимались методом t-SNE. Затем сжатые данные подавались на вход алгоритму DBSCAN. Результаты разделения для двух измерений на кластеры представлены на рис. 1.

По результатам разделения для двух измерений получилось 9 кластеров, что показывает возможность автоматической кластеризации стратегий игроков.

IV. ПРЕДЛАГАЕМОЕ РЕШЕНИЕ

В ходе исследования рассматривались конфигурации сетей с различным количеством скрытых слоёв. Архитектуры сетей представлены в табл. I, II, III. Основой для данных прототипов моделей послужила конфигурация нейронной сети в [9].

ТАБЛИЦА I. АРХИТЕКТУРА ПЕРВОГО ПРОТОТИПА НЕЙРОННОЙ СЕТИ

Слой	Параметры	Активация
Dense	units= number of grid	relu
Dropout	0.2	-
Dense	units= number of grid / 2	relu
Dense	units= number class	softmax

ТАБЛИЦА II. АРХИТЕКТУРА ВТОРОГО ПРОТОТИПА НЕЙРОННОЙ СЕТИ

Слой	Параметры	Активация
Dense	units= number of grid	relu
Dropout	0.2	-
Dense	units= number of grid / 2	relu
Dropout	0.1	-
Dense	units= number of grid / 3	relu
Dense	units= number class	softmax

ТАБЛИЦА III. АРХИТЕКТУРА ТРЕТЬЕГО ПРОТОТИПА НЕЙРОННОЙ СЕТИ

Слой	Параметры	Активация
Dense	units= number of grid	relu
Dropout	0.2	-
Dense	units= number of grid * 2	relu
Dense	units= number class	softmax

Исследования проводились на разном количестве эпох, от 100 до 1500. Для тестирования точности моделей, кроме отдельно выделенного набора данных, который не применялся в обучении, использовался метод кросс-валидации k-fold. В табл. IV показаны усреднённые результаты экспериментов.

Результаты, полученные в ходе исследования, показывают, что широкие нейронные сети менее точны в предсказании текущей стратегии противника, так как на всех трёх наборах показали наихудшие результаты точности. При этом глубокие нейронные сети точнее определяют текущую стратегию.




Рис. 1. Разделение по кластерам с размерностью 2, eps=3.35, min_samples=5

ТАБЛИЦА IV. АРХИТЕКТУРА ПЕРВОГО ПРОТОТИПА НЕЙРОННОЙ СЕТИ

Наборы данных	Прототип модели	Точность	
		Валидационные данные	Тестовые данные
Набор данных с учётом только видимых игроков на текущем такте игры	Первый	85-87%	77-79%
	Второй	87-89%	78-81%
	Третий	85-87%	75-77%
Набор данных с учётом недавно исчезнувших агентов	Первый	89-90%	80-82%
	Второй	88-92%	82-84%
	Третий	88-90%	79-82%
Набор данных с учётом с учётом недавно исчезнувших агентов на данных полученных методами «обучения без учителя»	Первый	92-94%	91-92%
	Второй	94-96%	91-94%
	Третий	91-93%	90-91%

V. ЗАКЛЮЧЕНИЕ

В рамках работы решалась задача определения стратегии агентов противника в виртуальном футболе на основе данных о местоположения игроков. Результаты, полученные в ходе исследования, показывают, что широкие нейронные сети менее точны в предсказании текущей стратегии противника, в то время как глубокие нейронные сети показывают большую точность. Полученные результаты по точности определения стратегии не хуже представленных аналогов, представленное решение можно использовать в дальнейшем для прогнозирования действий агентов и использовать совместно с системами принятия решений во время реальных соревнований.

СПИСОК ЛИТЕРАТУРЫ

- [1] Suzuki Y., Fukushima T., Thibout L., Nakashima T., Akiyama H. Game-watching should be more entertaining: real-time application of field-situation prediction to a soccer monitor // RoboCup 2019: Robot World Cup XXIII 23. Springer International Publishing, 2019. С. 439-447.
- [2] Visser A., Nardin L.G., Castro S. Integrating the latest artificial intelligence algorithms into the RoboCup rescue simulation framework // RoboCup 2018: Robot World Cup XXII 22. Springer International Publishing, 2019. С. 476-487.
- [3] Belyaev S.A. Mathematical Model of the Player Control in Soccer Simulation // 2021 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (ElConRus). IEEE, 2021. С. 233-237.
- [4] Fukushima T., Nakashima T., Akiyama H. Evaluation-function modeling with neural networks for RoboCup soccer // Electronics and Communications in Japan. 2019. Т. 102. №. 12. С. 40-46.
- [5] Кулинич А.А. Модель командного поведения агентов (роботов): когнитивный подход // Управление большими системами: сборник трудов. 2014. №. 51. С. 174-196.
- [6] Pourmehr S., Dadkhah C. An overview on opponent modeling in RoboCup soccer simulation 2D // RoboCup 2011: Robot Soccer World Cup XV 15. 2012. С. 402-414.
- [7] Akiyama H., Fukuyado M., Gochou T. and Aramaki S. Learning Evaluation Function for RoboCup Soccer Simulation using Humans' Choice // 2018 Joint 10th International Conference on Soft Computing and Intelligent Systems (SCIS) and 19th International Symposium on Advanced Intelligent Systems (ISIS). IEEE, 2018. С. 1416-1420.
- [8] Riley P., Veloso M. Recognizing probabilistic opponent movement models // RoboCup 2001: Robot Soccer World Cup V 5. Springer Berlin Heidelberg, 2002. С. 453-458.
- [9] Fukushima T., Nakashima T., Akiyama H. Online opponent formation identification based on position information // RoboCup 2017: Robot World Cup XXI 11. Springer International Publishing, 2018. С. 241-251.
- [10] Raabe D., Nabben R., Memmert D. Graph representations for the analysis of multi-agent spatiotemporal sports data // Applied Intelligence. 2023. Т. 53. №. 4. С. 3783-3803.
- [11] Kim S.H., Kim J.H., Lee J.H. The Role of a Reward in Shaping Multiple Football Agents' Behavior: An Empirical Study // Applied Sciences. 2023. Т. 13. №. 6. С. 3622.
- [12] Пантелеев М.Г., Салимов А.Ф. Анализ алгоритмов навигации интеллектуального агента в виртуальном футболе // Известия СПбГЭТУ «ЛЭТИ». 2020. №. 1. С. 60-70.
- [13] Дубровин Ф.С., Щербатюк А.Ф. Исследование некоторых алгоритмов однопояковой мобильной навигации АНПА: результаты моделирования и морских испытаний // Гирокоспия и навигация. 2015. №. 4. С. 160-172.
- [14] Cano P., Ruiz-del-Solar J. Robust tracking of multiple soccer robots using random finite sets // RoboCup 2016: Robot World Cup XX 20. Springer International Publishing, 2017. С. 206-217.
- [15] Petrunenko D.A., Belyaev S.A. Determining the Location of Players in Virtual Soccer // Software Journal: Theory and Applications. 2021. №2, С. 1-14.
- [16] Кучерский Р.В., Манько С.В. Алгоритмы локальной навигации и картографии для бортовой системы управления автономного мобильного робота // Известия Южного федерального университета. Технические науки. 2012. Т. 128. №. 3. С. 13-22.
- [17] RoboCupSimData Files Overview [Электронный ресурс]. URL: <http://oliver.obst.eu/data/RoboCupSimData/overview.html>. (дата обращения: 01.04.2023)