

Нейросетевое моделирование в физической подготовке юных легкоатлетов

Е.В. ОСИПЕНКО¹, А.В. НИКИТЮК^{1,2}, Ю.В. НИКИТЮК¹

В статье представлены результаты разработки нейросетевой модели для прогнозирования динамики уровня физической подготовленности юных легкоатлетов 10–12 лет. Искусственные нейронные сети были обучены и протестированы на основе антропометрических данных и результатов выполнения педагогических тестов 200 спортсменов. Результаты исследования подтверждают эффективность нейросетевых технологий для прогнозирования результатов в спортивной подготовке.

Ключевые слова: нейросетевое моделирование, физическая подготовка, юные легкоатлеты, прогнозирование результатов.

The article presents the results of the development of a neural network model for predicting the dynamics of the level of physical fitness of young athletes aged 10–12 years. The artificial neural networks were trained and tested based on anthropometric data and the results of pedagogical tests performed by 200 athletes. The results of the study confirm the effectiveness of neural network technologies for predicting results in sports training.

Keywords: neural network modeling, physical training, young track and field athletes, performance prediction.

Введение. Индивидуальный подход в физической подготовке юных легкоатлетов является ключевым фактором для достижения высоких спортивных результатов и предотвращения травм. Традиционные методы тренировки часто не учитывают возрастные, половые и морфофункциональные особенности спортсменов, что может привести к снижению эффективности подготовки и повышенному риску травматизма [1, р. 70–79].

Современные технологии в области искусственного интеллекта, особенно нейросетевые модели, открывают новые возможности для анализа больших объемов данных и выявления скрытых зависимостей в подготовке спортсменов [2, р. 180–182]. Однако текущие подходы часто ограничены и не полностью учитывают специфику легкоатлетических дисциплин [3, р. 64–65].

Цель исследования – разработать и экспериментально оценить нейросетевые модели для прогнозирования динамики физической подготовленности юных легкоатлетов на основе антропометрических данных и результатов тестов.

Задачи исследования:

- 1) провести обучение и тестирование нейросетевых моделей на реальных данных юных спортсменов;
- 2) определить наиболее эффективные архитектуры искусственных нейронных сетей для задач прогнозирования результатов юных легкоатлетов.

Методы исследования: анализ научно-методической литературы, педагогическое наблюдение, педагогическое тестирование, нейросетевое моделирование.

Основная часть. В последние годы наблюдается рост интереса к использованию нейросетевых технологий в спортивной подготовке, что обусловлено их способностью анализировать большие объемы данных и выявлять скрытые зависимости и закономерности [4, р. 516–525], [5, р. 56045–56058]. При этом традиционные подходы к физической подготовке юных легкоатлетов, основанные на стандартных тренировочных программах, не позволяют в полной мере учитывать индивидуальные особенности спортсменов.

Исследование проходило в 2023–2025 гг. на базе специализированного учебно-спортивного учреждения «Детско-юношеская спортивная школа Петриковского района» (Гомельская область) с участием юных легкоатлетов 10–12 лет в количестве 200 человек (100 юношей и 100 девушек).

Для прогнозирования динамики уровня физической подготовленности юных спортсменов были использованы различные архитектуры глубоких нейронных сетей, созданные с помощью библиотеки TensorFlow. Для создания моделей использовались функция активации ReLU и

адаптивный оптимизатор Adam. В качестве функции потерь применялась среднеквадратичная ошибка (MSE). Обучение сетей выполнялось в течение 500 эпох. При этом экспериментально исследовались различные архитектуры сетей для поиска оптимальной конфигурации.

На рисунке 1 представлена блок-схема процедуры нейросетевого моделирования [6].




Рисунок 1 – Блок-схема процедуры моделирования с использованием нейронной сети

В результате было обучено 25 искусственных нейронных сетей с количеством нейронов в двух скрытых слоях от 10 до 50 с шагом 10. Для тестирования сети использовались 10 вариантов параметров, представленных в таблице 1.

Таблица 1 – Данные для тестирования нейросетевых моделей

№	Класс	Пол (м/ж)	Рост (см)	Вес (кг)	Бег 30 м (сек)	Прыжок в длину с места (см)	Челночный бег 4 × 9 м (сек)	Метание мяча (м)	Бег на 800 м/500 м (мин)	Рост (см)	Вес (кг)	Бег 30 м (сек)	Прыжок в длину с места (см)	Челночный бег 4 × 9 м (сек)	Метание мяча (м)	Бег на 800 м/500 м (мин)
1	2	1	130	28	6.7	118	12.6	6	6.31	132	31	6.2	139	11.6	9	3.46
2	3	2	128	30	6.1	138	11.5	17	4.55	138	31	6.1	150	10.4	20	4.32
3	3	1	140	38	6.1	145	11.7	20	4.33	143	36	6.1	150	11.3	25	5.01
4	2	2	125	21	6.7	87	12.3	12	2.16	126	23	6.6	92	12.8	13	3.12
5	3	1	126	33	6.5	130	13.2	18	5.52	134	31	6.2	148	12.1	16	4.31
6	3	2	138	32	6.3	130	12.1	10	2.13	138	36	6.1	133	12.1	11	2.38
7	3	1	138	31	5.9	130	11.1	18	3.26	145	29	5.7	161	10.1	27	5.32
8	2	2	130	23	5.9	150	11.5	12	4.16	135	26	5.6	160	11.1	10	2.06
9	2	1	135	24	7	154	11.4	10	4.41	137	26	6.2	158	11.2	13	4.32
10	2	1	135	22	6.5	150	11.5	10	4.42	139	24	6.3	157	12.1	12	4.14

Для оценки эффективности работы нейронных сетей были использованы следующие критерии:

– средняя абсолютная ошибка (англ. Mean Absolute Error, MAE)

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |d_i - y_i|,$$

– среднеквадратичная ошибка (англ. Root Mean Square Error, RMSE)

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (d_i - y_i)^2},$$

– средняя абсолютная процентная ошибка (англ. Mean Absolute Percentage Error, MAPE)

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{d_i - y_i}{d_i} \right| \times 100,$$

где d_i – желаемый выход сети, y_i – реальный выход сети.


В качестве входных параметров для нейросетевого моделирования были использованы класс, пол, рост и вес спортсменов. Также в качестве входных параметров были использованы результаты бега на 30 м, прыжка в длину с места, челночного бега 4 по 9 м, метания мяча и бега на 500 м и 800 м (для девочек и мальчиков соответственно). При этом рост, вес и результаты по выполнению указанных выше упражнений через год использовались в качестве выходных параметров для нейросетевых моделей.

В результате было обучено 25 искусственных нейронных сетей с количеством нейронов в двух скрытых слоях от 10 до 50 с шагом 10. Для тестирования сети использовались 10 вариантов параметров.


Анализ проверки точности прогнозирования с использованием метрик MAE, MSE и MAPE позволяет констатировать, что наилучшие результаты при определении выходных параметров (длина тела, масса тела, результаты бега на 30 м, прыжка в длину с места, челночного бега 4 × 9 м, метания мяча и бега на 500/800 м) соответственно показали нейронные сети с архитектурами [9-10-50-7], [9-50-10-7], [9-10-10-7], [9-10-40-7], [9-50-50-7], [9-30-20-7], [9-40-10-7] соответственно. При этом средняя абсолютная процентная ошибка для выходных параметров не превысила 5 %.

На рисунках 2–3 приведены примеры тепловых карт, демонстрирующие распределение валидационных ошибок при определении выходных параметров. При этом вертикальная и горизонтальная оси показывают количество нейронов в первом и втором скрытых слоях искусственных нейронных сетей.


Созданные нейросетевые модели в дальнейшем будут использованы для индивидуального прогнозирования результатов юных легкоатлетов, что позволит тренерам и спортсменам более эффективно планировать тренировочный процесс и корректировать его в зависимости от прогнозируемых результатов.



а)




б)



в)

Рисунок 2 – Распределение ошибок (RMSE (а), MAE (б), MAPE (в)) для различных архитектур нейросетей при прогнозировании результатов бега на 30 м



а)




Рисунок 3 – Распределение ошибок (RMSE (а), MAE (б), MAPE (в)) для различных архитектур нейросетей при прогнозировании результатов челночного бега 4×9 м

Нейросетевое прогнозирование индивидуальных результатов юных легкоатлетов является перспективным инструментом для повышения эффективности тренировочного процесса и достижения высоких спортивных результатов.

Несмотря на хорошую точность, полученные модели имеют ограничения, связанные с количеством данных. Поэтому в дальнейшем планируется увеличить количество участников и включить спортсменов из разных регионов разного возраста и уровня спортивной квалификации для повышения эффективности нейросетевой модели. Также для дальнейшего улучшения нейросетевой модели необходимо учитывать дополнительные факторы. Для удобства использования нейросетевой модели планируется разработать мобильный интерфейс для тренеров и спортсменов, позволяющий оперативно собирать данные, расширить набор входных параметров и получать рекомендации в режиме реального времени.

Заключение. Разработанная нейросетевая модель продемонстрировала высокую точность прогнозирования динамики физической подготовленности юных легкоатлетов. Полученные результаты показывают целесообразность применения нейросетевых технологий для анализа данных в юношеском спорте. **Разработка мобильного интерфейса** для автоматизации сбора данных и визуализации прогнозов в режиме реального времени и дальнейшее развитие модели, включая расширение выборки, учет дополнительных параметров, данные о тренировочных нагрузках, восстановлении и психологическом состоянии юных легкоатлетов, позволит повысить ее точность и практическую значимость для тренеров и спортсменов.

Литература

1. Baca, A. Rapid feedback systems for elite sports training / A. Baca, P. Kornfeind // IEEE Pervasive Computing. – 2012. – Vol. 11, № 3. – P. 70–79.
2. Fister, I. Jr. Computational intelligence in sports : challenges and opportunities within a new research domain / I. Fister Jr., X. S. Yang, I. Fister, Y. Jiang // Applied Mathematics and Computation. – 2015. – Vol. 262. – P. 178–186.
3. James, N. The development of position-specific performance indicators in professional rugby union / N. James, S. Mellalieu, N. Jones // Journal of Sports Sciences. – 2005. – Vol. 23, № 1. – P. 63–72.
4. Liu, H. Modelling relationships between match events and match outcome in elite football / H. Liu, W. G. Hopkins, M. A. Gómez // European Journal of Sport Science. – 2016. – Vol. 16, № 5. – P. 516–525.
5. Li, X. Big data and deep learning in elite sports : A review and practical applications / X. Li, H. Wang, X. Luo // IEEE Access. – 2021. – № 9. – P. 56045–56058.
6. Nikitjuk, Yu. V. Determination of the parameters of two-beam laser splitting of silicate glasses using regression and neural network models / Yu. V. Nikitjuk, A. N. Serdyukov, I. Y. Aushev // Journal of the Belarusian State University. Physics. – 2022. – № 1. – P. 35–43.

¹Гомельский государственный
университет имени Франциска Скорины

²ГУО «Мышанская средняя школа»

Поступила в редакцию 27.01.2025