Научная статья
УДК 685.34
EDN FVVYKS
https://doi.org/10.34216/2587-6147-2026-3-73-70-76
Евгений Евгеньевич Смирнов[1]
Валентина Владимировна Костылева[2]
Альфия Рустямовна Муртазина[3]
[1,2,3] Российский государственный университет им. А. Н. Косыгина (Технологии. Дизайн. Искусство), Москва, Россия
[1] evg7162@mail.ru; https://orcid.org/0000-0003-1465-1894
[2] kostyleva-vv@rguk.ru; https://orcid.org/0000-0002-9124-4849
[3] aly1029@yandex.ru; https://orcid.org/0000-0002-1008-1276

ИСПОЛЬЗОВАНИЕ РЕКУРРЕНТНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ОБРАБОТКИ ПОСЛЕДОВАТЕЛЬНОСТЕЙ ОРТОПЕДИЧЕСКИХ ДАННЫХ

Аннотация. *Персонализация ортопедических изделий повышает комфорт их использования пациентами, но требует много ресурсов. Качественное производство такого изделия сопряжено с проведением ряда обследований, для которых характерно большое количество выходных данных. Сокращению временных затрат на их обработку и анализ может служить применение нейронных сетей рекуррентной архитектуры. Однако, принципы построения таких сетей и оценивание их эффективности существенно варьируются от задачи к задаче. В настоящей статье рассмотрены вспомогательные критерии, повышающие объективность выбора соответствующей архитектуры.*
Ключевые слова: *нейронные сети, ортопедическая обувь, ортопедические стельки, подограф, рекуррентные нейронные сети, машинное обучение, маскирующий слой*

Для цитирования: Смирнов Е. Е., Костылева В. В., Муртазина А. Р. Использование рекуррентных нейронных сетей для обработки последовательностей ортопедических данных // Технологии и качество. 2026. № 3(73). С. 70–76. https://doi.org/10.34216/2587-6147-2026-3-73-70-76.

Original article
Evgeniy E. Smirnov[1]
Valentina V. Kostyleva[2]
Al'fiya R. Murtazina[3]
[1,2,3] Kosygin Russian State University (Technology. Design. Art), Moscow, Russia

USING RECURRENT NEURAL NETWORKS FOR ORTHOPEDIC DATA SEQUENCES' PROCESSING

Abstract. *Personalization of orthopedic products increases the comfort of their use by patients, but requires a lot of resources. High-quality production of such a product is associated with a number of surveys, which are characterized by a large amount of output data. The use of recurrent architecture neural networks can reduce the time spent on their processing and analysis. However, the principles of building such networks and evaluating their effectiveness vary significantly from task to task. This article discusses auxiliary criteria that enhance the objectivity of choosing the appropriate architecture.*
Keywords: *Neural networks, orthopedic shoes, orthopedic insoles, podograph, recurrent neural networks, machine learning, mask*

For citation: Smirnov E. E., Kostyleva V. V., Murtazina A. R. Using recurrent neural networks for orthopedic data sequences' processing. Technologies & Quality. 2026. No 3(73). P. 70–76. (In Russ.) https://doi.org/10.34216/2587-6147-2026-3-73-70-77.

Вкладные ортопедические стельки несмотря на свою кажущуюся простоту в некоторых ситуациях являются единственным эффективным способом корректировки и/или компенсации различных дефектов походки, осанки, стоп. Важным аспектом представляется персонализированный подход. Исследования показы-

© Смирнов Е. Е., Костылева В. В., Муртазина А. Р., 2026

вают существенный отклик организма на индивидуально разработанные стельки по сравнению с массовыми изделиями [1–3].

Для своевременного удовлетворения спроса на персонализированные изделия и повышения конкурентоспособности необходимо снизить затраты на производство за счет автоматизации части процессов, требующих вовлеченности дорогостоящего специалиста. В современных условиях такие задачи позволяют решать нейронные сети.

Данные пациента, снимаемые с использованием различных устройств, представляют собой сложную структуру. Большая их часть, как результат динамического и постурального обследований, является временными последовательностями. В настоящей статье для обработки таких данных выбраны рекуррентные нейронные сети (РНС, англ. Recurrent neural network, RNN) – вид нейронных сетей, где связи между элементами образуют направленную последовательность, поэтому появляется возможность обрабатывать серии событий во времени или последовательные пространственные цепочки [4, 5]. Задача настоящего исследования сводится к определению наиболее эффективной ее архитектуры применительно к вопросам обработки результатов комплексных скрининговых исследований.

Исходные данные. Информацию о нагрузке плантарной поверхности стоп, устойчивости человека и стато-локомоторных функциях позволяет получить постуральное обследование [6, 7]. Всего в процессе данного исследования собирается 56 показателей различной структуры. Некоторые из них представлены в виде последовательности данных. Следовательно, необходимо проанализировать эффективность применения рекуррентных нейронных сетей для обработки значений, полученных в рамках указанного обследования, как значительную часть всей архитектуры. Для примера взяты центры давления каждой стопы в отдельности и общий центр тяжести как один из важнейших факторов этого исследования.

В каждый момент времени фиксируются три точки с координатами X и Y, которые определяют вектор из шести чисел. Для проведения исследования нами использована информация о 1065 пациентах. На рисунке 1 представлено распределение данных по всем пациентам для каждой координаты. Созданы интервалы от –190 до 190 с шагом 10, и рассчитана частота попаданий значений в эти интервалы.

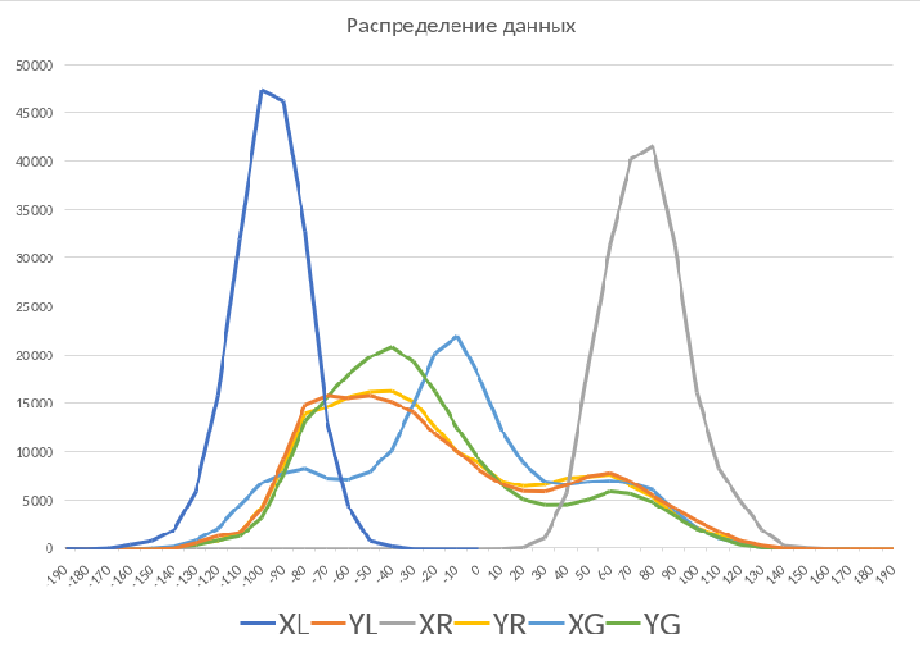


Рис. 1. Распределение данных:
XL – координата X левой ноги; YL – Y левой ноги; XR – X правой ноги; YR – Y правой ноги; XG – X центра тяжести; YG – Y центра тяжести

Распределение данных по координатам, связанным с X, похоже на нормальное распределение с маленьким стандартным отклонением, что довольно просто объясняется исходной постановкой стоп на подограф и шириной самой стопы. Также поперечное раскачивание менее подвержено изменению центра масс тела. В случае паталогий скорее будет диспропорция силы давления, чем смещение центра тяжести. Распределения координат Y обладают заметной асимметрией. Коэффициент асимметрии для координаты Y_GLOBAL равен примерно 0,74,

второй коэффициент асимметрии Пирсона – 0,42, что оценивается как умеренная асимметрия. Плотность распределения, среднее, медиана и мода представлены на рисунке 2.

Такое смещение в сторону отрицательных значений с точки зрения анализа походки указывает на повышенную нагрузку в пяточной области стоп у подавляющего количества пациентов.

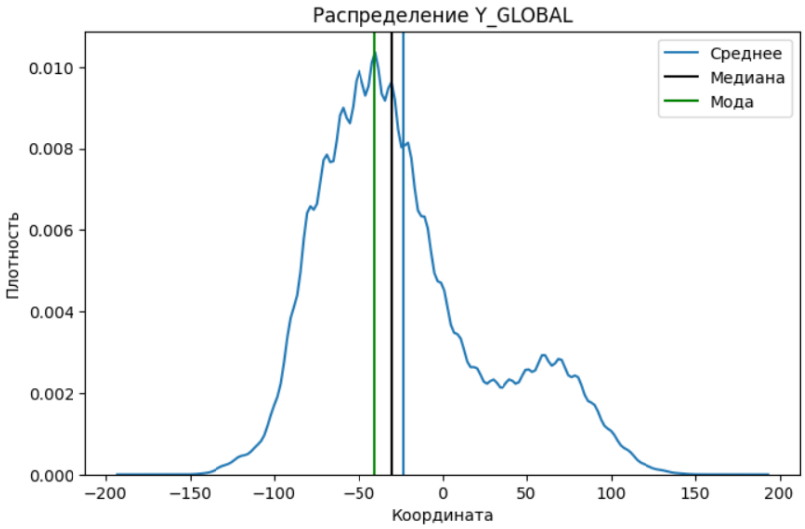


Рис. 2. Плотность распределения Y_GLOBAL со статистическими данными

Обработка данных. Для быстрого и качественного обучения сети необходимо правильно представить входные данные. Первый шаг заключается в их нормировании. Чтобы функции активации рекуррентных блоков не уходили в области насыщения, данные должны находиться в диапазоне [0; 1]. Тогда нормирование производится так, чтобы данные, поступающие в будущем, не выходили за эти границы, поэтому задействованные значения помещаются в диапазон [0,1; 0,9].

Общая продолжительность обследования занимала различное время. Количество кадров у пациентов варьируется от 50 до 300. При тестировании и функционировании нейронных сетей это не является проблемой, но не для обучения. Для него структура входной информации должна быть однородна. Для выравнивания размерности данные необходимо дополнить: чаще всего применяется предварительное заполнение 0 [8]. В результате получаем массив размерностью 300×6, разбитый на объясняющую часть (290×6) и объясняемую (10×6).

Результаты эксперимента. В эксперименте реализовано три подхода к построению нейронной сети: рекуррентная сеть, переходящая в полносвязную (далее masking), дающая на выходе тензор размерностью (10,6), сеть на основе кодирования и декодирования (далее gen), пошагово порождающая вектор из шести чисел в течение 10 итераций, и сеть, построенная по принципу Direct, где несколько рекуррентных сетей, получая один вход, предсказывают фрагмент выхода через полносвязный блок (далее Direct) (табл. 1).

Необходимость заполнения данных нулями, которые в некоторых случаях занимают 83,(3) % может вносить серьезные корректировки в восприятие нейронной сетью данных. Для исключения этого эффекта предлагается ввести маскирующий слой (masking layer), который позволяет пропускать данные, соответствующие маске. В нашем случае маска (0.0, 0.0, 0.0, 0.0, 0.0, 0.0). Сравнение двух сетей с разницей только в masking-слое представлено в таблице 2. Время тестирования ухудшилось приблизительно на 20 %, показатели функции потерь лучше на 67 %, а средний квадрат ошибок по среднему значению каждой координаты с тестовыми данными лучше в 6 раз.

Принцип вычисления показателей MSE (рис. 3) разберем на примере среднего значения. По результатам тестирования сети формируется массив данных, имеющий размерность (65, 10, 6), – десять предсказаний шести параметров для каждого пациента. Далее рассчитывается среднее значение по каждому параметру как ответа нейронной сети, так и тестового множества. После чего вычисляется средняя разность квадратов по всем параметрам всех образцов.

Таблица 1

Структура нейронных сетей

Direct		Masking		Gen	
Слой	**Предыдущий**	**Слой**	**Предыдущий**	**Слой**	**Предыдущий**
input_layer	-	input_layer	-	encoder_input	-
masking	input_layer	masking	input_layer	masking	encoder_input
lstm	masking	lstm	masking	lstm_63	masking,
lstm_1	masking	lstm_1	lstm	lstm_64	lstm_63
lstm_2	masking	lstm_2	lstm_1	lstm_65	lstm_64
lstm_3	masking	lstm_3	lstm_2	decoder_input	-
lstm_4	masking	dense	lstm_3	encoder	lstm_65
lstm_5	masking	dense_1	dense	lstm_66	decoder_input
lstm_6	masking	dense_2	dense_1		encoder[1],
lstm_7	masking	dense_3	dense_2		encoder[2]
lstm_8	masking	dense_4	dense_3	lstm_67	lstm_66
lstm_9	masking	reshape	dense_4	Dense_1	lstm_67
dense	lstm			dense_2	dense_1
dense_1	lstm_1			dense_3	dense_2
dense_2	lstm_2			reshape	dense_3
dense_3	lstm_3				
dense_4	lstm_4				
dense_5	lstm_5				
dense_6	lstm_6				
dense_7	lstm_7				
dense_8	lstm_8				
dense_9	lstm_9				
concatenate	dense,				
	dense_1,				
	dense_2,				
	dense_3,				
	dense_4,				
	dense_5,				
	dense_6,				
	dense_7,				
	dense_8,				
	dense_9				
reshape	concatenate				

Таблица 2

Результаты тестирования маскирующего слоя

Параметр	Без маскирующего слоя	С маскирующим слоем	NS1 / NS2
MSE по средним значениям координат	7,5311E-03	1,2621E-03	597 %
Тестовые показатели потерь	1,8492E-02	1,1061E-02	167 %
Время на тестирование, мс/шаг	36	43	84 %

NSi	Test loss	MSE				
		mean	var	std	min	max
masking	1,10E-02	8,81E-04	8,52E-05	4,31E-03	3,09E-02	5,10E-02
gen	1,13E-02	3,32E-03	3,24E-05	1,13E-03	3,56E-02	7,10E-02
Direct	1,38E-02	6,20E-04	1,49E-05	4,15E-04	1,18E-02	1,88E-03
NSi	NSi/NS3					
	Test loss	mean	var	std	min	max
masking	80%	142%	571%	1037%	262%	2715%
gen	82%	536%	217%	272%	302%	3781%
Direct	100%	100%	100%	100%	100%	100%

Рис. 3. Сравнение статистических показателей предсказаний с тестовым множеством

Такой подход позволяет оценить, насколько близко распределение данных к исходному. На рисунке 3 в верхней части таблицы показаны абсолютные значения статистических данных с тепловой картой «больше – хуже». В нижней значения относительно сети Direct – аналогичная тепловая карта. Если принять во внимание только показатель потерь, то сеть

Direct получается хуже masking на 25 %, а gen – на 21,9 %. Однако все остальные показатели этой сети существенно лучше и проигрыш gen и masking колеблется от 42 % в лучшем случае до 3 681 % в худшем. Если сравнить gen и masking между собой, то получается, что сеть masking лучше предсказывает конкретные значения, но уступает по разбросу. В таблице 3 представлены значения коэффициента детерминации по каждой сети.

Таблица 3

Значения коэффициента детерминации

R^2		
masking	**Direct**	**gen**
–0,153	0,406	–5,364

Лучшими показателями обладает Direct, masking чуть хуже среднего, gen вообще не дает корректных данных, что согласуется с предсказаниями, представленными на рисунке 4.

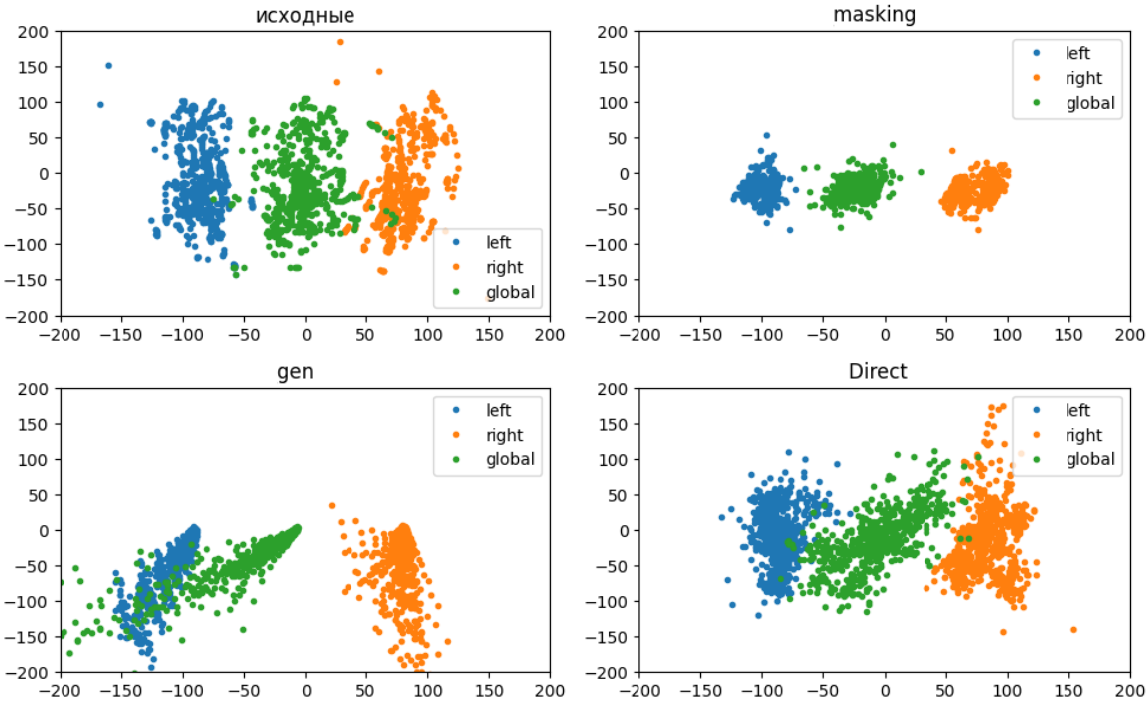


Рис. 4. Предсказания моделей в сравнении с исходными данными

Сравнение с авторегрессионной моделью. Для обработки последовательностей сигналов применяется множество различных подходов: учитывающие авторегрессионную компоненту (**Auto Regressive,** AR), скользящая средняя (**Moving Average,** MA), дифференцирование (**Integrated,** I), сезонность (**Seasonal,** S) и их комбинации. При тестировании всех рядов датасета на стационарность у многих показатель p-value существенно превышал порог 0,05, следовательно, гипотезу о стационарности нужно отклонить. Приведение рядов к стационарному виду осуществлялось при помощи дифференцирования первого порядка. После чего показатель p-value у всех рядов стал существенно ниже 0,01. Пример преобразованного в стационарный ряда Y_GLOBAL представлен на рисунке 5.

К стационарному ряду можно применять методы AR и MA, но их сочетание является более эффективным. Добавляя дифференцирование, получается метод ARIMA. Процесс обучения модели заключается в подборе порядков авторегрессии и скользящего среднего для модели AR и MA для наиболее эффективного предсказания. Порядок дифференцирования не участвовал в обучении моделей, так как первого преобразования оказалось достаточно и тренировка осуществлялась уже на дифференцированных данных. В этом случае для каждого ряда обучалась своя модель для получения максимальной точности. На выходе всего 1065 пациентов × 6 рядов = 6390 моделей. После получения предсказаний данные восстанавливались и сравнивались с предсказаниями нейронной сети. Коэффициент детерминации у сети Direct составил 0,406958967, у ARIMA = 0,360195488. Эти показатели являются довольно близкими, однако стоит посмотреть на предсказания (рис. 6). Здесь видно, насколько более гибко нейронная сеть пытается описать выходные данные, по сравнению с авторегрессионной моделью, несмотря на то, что в случае ARIMA для каждого ряда применяются свои параметры.

ARIMA также уступает нейронной сети в скорости функционирования. После обучения время на тестирование 65 рядов составило всего 3 с. Для применения ARIMA необходимо обучение для каждого ряда ($65 \cdot 6 = 390$), которое требует временных затрат, достигающих в некоторых случаях 50 с (рис. 7). Еще одним преимуществом обученной нейронной сети является ее гибкость в интеграции в более сложные структуры. Всегда есть возможность включить обученные фрагменты в новую архитектуру и либо дообучить ее, либо использовать в исходном виде. Авторегрессионные модели лишены этой возможности.

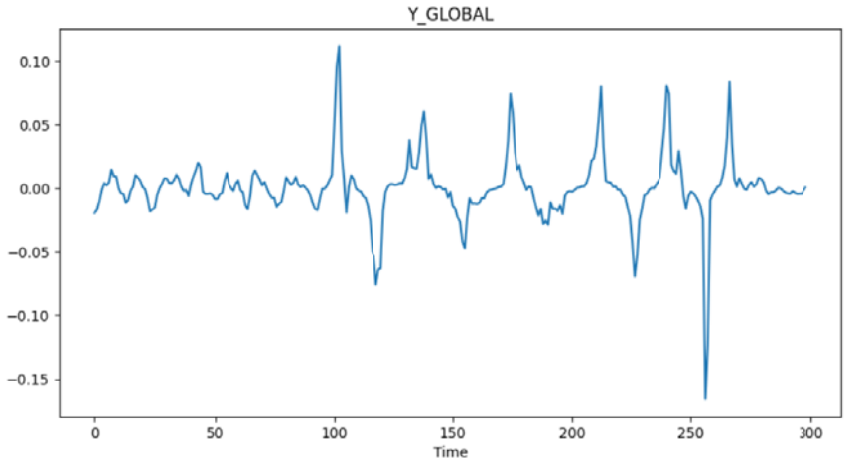


Рис. 5. Стационарный ряд Y_GLOBAL

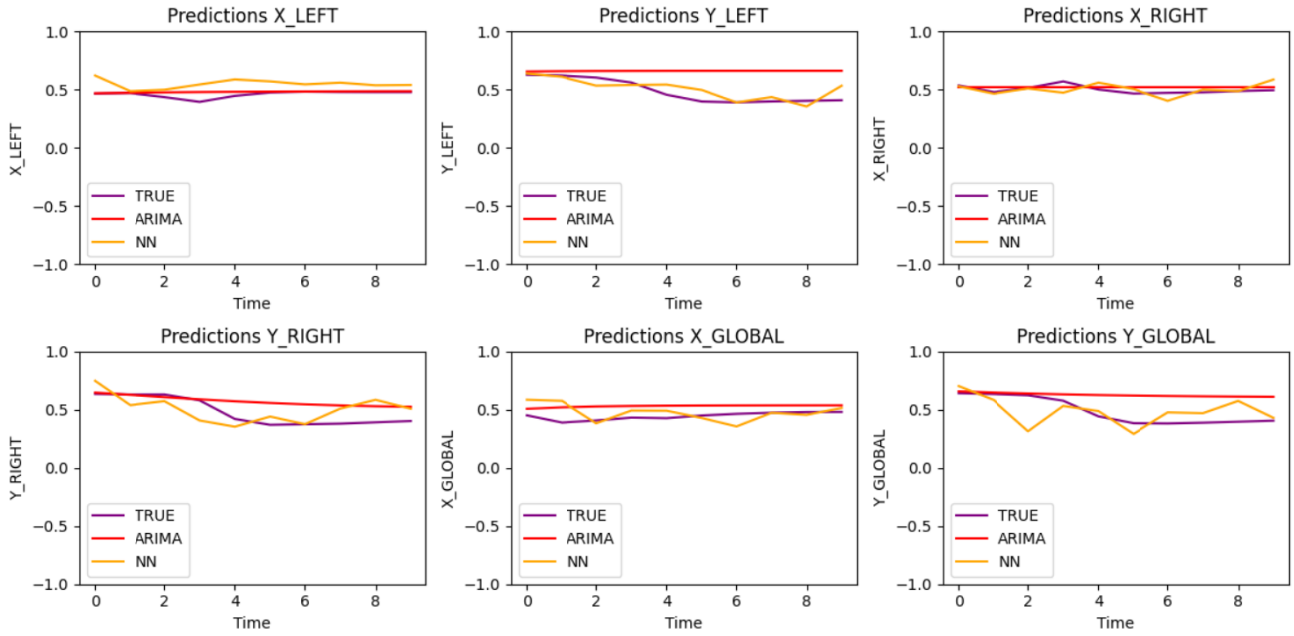


Рис. 6. Предсказания моделей:
TRUE – исходные данные; ARIMA – предсказание авторегрессионных моделей; NN – предсказания нейронной сети

```
Best model:  ARIMA(7,0,7)(0,0,0)[0]
Total fit time: 49.969 seconds
```

Рис 7. Время обучения ARIMA

ВЫВОДЫ

Рекуррентные нейронные сети позволяют с достаточной точностью предсказывать продолжение временного ряда в задачах анализа данных плантарных поверхностей стоп пациентов. В ходе исследования были представлены три основных идеи построения рекуррентных сетей и возможность их применения, а также необходимость применения masking-слоя. Для успешного применения необходимо учитывать специфику задачи и подбирать как соответствующую архитектуру, так и критерии оценивания.

СПИСОК ИСТОЧНИКОВ
1. Диагностика и коррекция постуральных нарушений, обусловленных дисплазией тазобедренного сустава у детей / Д. В. Долганов, Т. И. Долганова, М. П. Тепленький, Е. В. Олейников // Гений ортопедии. 2013. № 1. С. 40–43.
2. Баиндурашвили А. Г., Соловьева К. С., Залетина А. В. Инвалидность детского населения России вследствие травм и заболеваний костно-мышечной системы // Гений ортопедии. 2013. № 1. С. 5–8.
3. Скрябин Е. Г., Дуров М. Ф., Прокопьев Н. Я. Новый безопасный метод диагностики деформаций позвоночного столба и система немедикаментозного лечения вертеброгенного болевого синдрома у беременных женщин // Гений ортопедии. 2003. № 1. С. 14–16.
4. Isaeva A. S., Denisenko M. A., Kots I. N. Testing the layout of the rail condition monitoring system using LSTM recurrent neural networks // St. Petersburg State Polytechnical University Journal. Physics and Mathematics. 2022. Vol. 15, no. S3.2. P. 51–55.
5. Brokarev I. A., Farkhadov M. P., Vaskovskiy S. V. Recurrent neural networks to analyze the quality of natural gas // Вестник Томского государственного университета. Управление, вычислительная техника и информатика. 2021. № 55. P. 11–17.
6. Муравьева Н. В. Диагностика и коррекция постуральных нарушений у пациентов с гемигипоплазией : автореф. дис. … канд. мед. наук. М., 2015. 22 с.
7. Определение позиции стоп на изображении с применением сверточной нейронной сети / Е. Е. Смирнов, В. В. Костылева, А. Р. Муртазина [и др.] // Костюмология. 2023. Т. 8, № 3. URL: https://kostumologiya.ru/PDF/29TLKL323.pdf (дата обращения: 10.03.2026).
8. Training of Recurrent Neural Networks (RNN) in TensorFlow. URL: https://www.geeksforgeeks.org/deep-learning/training-of-recurrent-neural-networks-rnn-in-tensorflow (дата обращения: 26.09.2025).

REFERENCES
1. Dolganov D. V., Dolganova T. I., Teplen’kii M. P., Oleinikov E. V. Diagnostics and correction of postural disorders due dysplasia of the hip in children. *Genij ortopedii* [The genius of orthopedics]. 2013;1:40–43. (In Russ.)
2. Baindurashvili A. G., Solov’eva K. S., Zaletina A. V. Disability of Russia children population due to injuries and diseases of the locomotor system. *Genij ortopedii* [The genius of orthopedics]. 2013;1:5–8. (In Russ.)
3. Skriabin E. G., Durov M. F., Prokopiyev N. Ya. A new safe method for diagnostics of the spine deformities and a system of non-medicamentous treatment of the pain vertebrogenic syndrome in pregnant women. *Genij ortopedii* [The genius of orthopedics]. 2003;1:14–16. (In Russ.).
4. Isaeva A. S., Denisenko M. A., Kots I. N. Testing the layout of the rail condition monitoring system using LSTM recurrent neural networks. St. Petersburg State Polytechnical University Journal. Physics and Mathematics. 2022;15,S3.2:51–55.
5. Brokarev I. A., Farkhadov M.P., Vaskovskii S. V. Recurrent neural networks to analyze the quality of natural gas. *Vestnik Tomskogo gosudarstvennogo universiteta. Upravlenie, vychislitel’naya tekhnika i informatika* [Tomsk State University Journal. Control and Computer Science]. 2021;55:11–17.
6. Murav’eva N. V. Diagnosis and correction of postural disorders in patients with hemihypoplasia. Abstract Cand. Med. Sci. dis. Moscow, 2015. 22 p. (In Russ.)
7. Smirnov E. E., Kostyleva V. V., Murtazina A. R., Razin I. B., Sergeev V. A. Determining the position of the feet in the image using a convolutional neural network. *Kostyumologiya* [Journal of Clothing Science]. 2023;8(3):29TLKL323. URL: https://kostumologiya.ru/PDF/29TLKL323.pdf (accessed 10.03.2026). (In Russ.)
8. Training of Recurrent Neural Networks (RNN) in TensorFlow. URL: https://www.geeksforgeeks.org/deep-learning/training-of-recurrent-neural-networks-rnn-in-tensorflow (accessed 26.09.2025).

Статья поступила в редакцию 25.03.2026
Принята к публикации 02.07.2026

ИНФОРМАЦИЯ ОБ АВТОРАХ
Е. Е. Смирнов, кандидат технических наук, доцент
В. В. Костылева, доктор технических наук, профессор
А. Р. Муртазина, кандидат технических наук, доцент