

# ИСПОЛЬЗОВАНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПРОГНОЗИРОВАНИЯ ВРЕМЕННЫХ РЯДОВ

Дроздовская П. К., Сиколенко М. А., Качук И. А., Мозоль Н. Р., Лутковский В. М.  
Кафедра системного анализа и компьютерного моделирования,  
Белорусский государственный университет  
Минск, Республика Беларусь  
E-mail: d.apolinaria@gmail.com, lutkovski@bsu.by

*Данная работа посвящена прогнозированию временных рядов с помощью нейронных сетей, включая задачи предсказания мелодии и курса валют.*

## I. ВВЕДЕНИЕ

Одним из ключевых направлений в анализе данных является предсказание временных рядов. Целью данного проекта является разработка и обучение моделей глубокого обучения. В работе рассматриваются две задачи, каждая из которых иллюстрирует принцип работы нейронных сетей в контексте предсказания последовательности данных, а именно мелодии Э.Ханка «Малиновка» и прогнозирование курса белорусского рубля. Основные этапы проекта включают в себя формирование и предобработку набора данных, разработка и обучение моделей, подбор гиперпараметров и их оптимизация, а также оценка и сравнение точности моделей с использованием ключевых метрик качества, таких как MAPE и MSE. Результаты проекта помогут выявить преимущества и недостатки различных подходов к прогнозированию временных рядов и предложить эффективные решения по исследованию точности предсказания нейронных сетей при работе с различными типами данных.

## II. ПРЕДСКАЗАНИЕ МЕЛОДИИ

Первая задача – предсказание мелодии «Малиновка» – представляет собой интересный пример использования нейронных сетей для обработки и анализа музыкальных данных. Мелодии можно рассматривать как временные ряды, поскольку они представляют собой последовательности звучащих нот с определенной структурой и ритмом. Применение нейронной сети позволяет выявить скрытые паттерны и зависимости в музыкальном ряде. Методология включает предварительную обработку данных, создание модели нейронной сети для обучения и тестирования на нормализованных и дополненных данных.

**Параметры сети.** Модель нейронной сети была построена с использованием двух скрытых слоев, каждый из которых содержит 15 нейронов. Такой выбор архитектуры позволяет учесть сложные зависимости в данных мелодии, что критически важно для временных рядов, характеризующихся периодическими изменениями и шумом. Обучение проводилось на данных с 10 эпохами, что обеспечивало достаточную адаптацию модели к исходным данным. Обработка данных. Исход-

ный временной ряд состоял из последовательности частот, соответствующих нотации мелодии. Для улучшения качества предсказаний:

1. **Детрендинг:** Исходные данные были скорректированы с учетом тренда, что позволяет более точно выявлять колебания.
2. **Нормализация:** Данные были нормализованы для устранения смещения и различий в масштабах.
3. **Аугментация:** Для повышения устойчивости модели добавлялся шум, что позволило создать несколько копий нормализованных данных (14 реплик).

## III. ПРЕДСКАЗАНИЕ КУРСА ВАЛЮТ

**Исходные данные курса валют.** Данные взяты с сайта национального банка Республики Беларусь 2018-2024 года, с ежедневными данными по курсу белорусского рубля по отношению к американскому доллару.

Исходный набор данных разбит на 2 периода: "Период до пандемии COVID-19" (прековидный период) и "Период после пандемии COVID-19" (постковидный период). Это связано с тем, что экономические показатели до пандемии могут следовать одному тренду, тогда как в постковидный период тренд мог измениться из-за резких перемен в мировой экономике. Временной ряд для каждого из периодов разбит последовательно на тренировочную и тестовую выборки в соотношении 8:2. Одним из гиперпараметров при Байесовской оптимизации выступает "Шкалирование", "Нормализация" или "Сырые данные". Выбор параметра зависит от решаемой задачи и входных данных.

## IV. АРХИТЕКТУРА И ПАРАМЕТРЫ МОДЕЛЕЙ ПРЕДСКАЗАНИЯ КУРСА ВАЛЮТ

**Модель ARIMA.** Основные параметры модели ARIMA ( $p, d, q$ ) были определены с помощью модуля `pmdarima auto_arima`. Данные шкалировались перед подачей на вход модели ARIMD. Для данных пост-ковидного периода значения параметров составили (1,1,0) и метрика качества MSE составила 0.53, а для пре-ковидного периода – (0,0,1) MSE = 0.42. Модели ARIMA показали низкие значения метрик качества и не продемон-

стрировали способность предсказания курса белорусского рубля.

Для улучшения качества прогноза была подобрана оптимальная архитектура для модели рекуррентной нейронной сети. Основные компоненты используемой модели включают:

- **Входной слой:** содержит  $N = 32$  нейронов, представляющих количество временных лагов, на основе которых формируется прогноз.
- **Рекуррентные слои:** количество последовательно идущих рекуррентных слоёв  $m = 4$ . В качестве базового слоя используются ячейки LSTM/GRU.
- **Скрытые слои:** каждый скрытый слой (LSTM/GRU) содержит  $n = 48$  нейронов.

Параметры  $m = 4$ ,  $n = 48$ ,  $N = 32$ , а также тип рекуррентного слоя были оптимизированы с использованием метода автоподбора гиперпараметров на основе Байесовской оптимизации.

## V. РЕЗУЛЬТАТЫ И ЗАКЛЮЧЕНИЕ

**Мелодия.** После выполнения предобработки данных и их разделения на обучающую и тестовую выборки, сеть была обучена на 80% данных. До обучения, среднеквадратичная ошибка (MSE) на обучающем наборе составила 0.216, что свидетельствует о низком уровне ошибки на начальном этапе. После обучения результаты также характеризуются высокой точностью: при тестировании модели на оставшихся данных MSE составила 1.388, что указывает на возможность предсказания мелодии с приемлемой точностью.

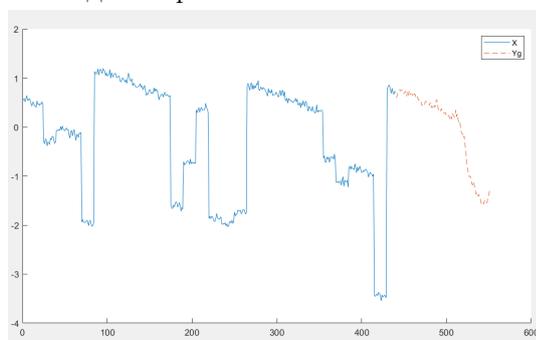


Рис. 1 – Предсказание мелодии

**Курс Валют.** Реализована и обучена модель для и предсказания курсов белорусского рубля; исследована зависимость точности прогноза от и предобработки данных, а также от гиперпараметров модели. Решены задачи –

1. Формирования набора данных;
2. Создание шаблона базовой модели нейронной сети для лёгкости масштабируемости и тестирования различных конфигурация гиперпараметров;
3. Нахождение и обучение оптимальных параметров модели ARIMA;
4. Нахождение и обучение оптимальных параметров модели рекуррентной нейронной сети;

## 5. Тестирование и верификация результатов разработанной модели.

Таблица 1 – Метрики качества предпандемийного и постпандемийного периода

Метрика	Пре-пандемийный	Пост-пандемийный
MAE	0.00367	0.00816
medAE	0.00216	0.00489
MSE	2.53e-05	0.00016
MSLE	2.59e-06	8.94e-06
MAPE	0.00174	0.00256

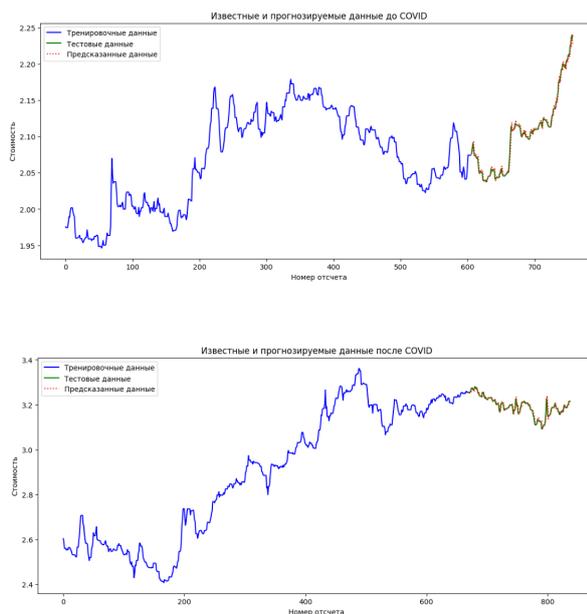


Рис. 2 – Предсказание курса валют

Общие выводы по данной работе демонстрируют эффективность нейронных сетей для предсказания временных рядов разного типа. Задача по предсказанию мелодии «Малиновка» показала, что глубокие нейронные сети могут выявлять скрытые зависимости и структуру музыкальных данных, что позволяет достигать точных предсказаний нот. Анализ курсов валют показал значительное преимущество рекуррентных нейронных сетей над традиционной моделью ARIMA, особенно в пост-пандемийный период, благодаря возможности учета долгосрочных зависимостей. Полученные результаты подчеркивают важность выбора и настройки архитектуры модели в зависимости от типа данных и задачи. Работа подтверждает перспективность использования глубокого обучения для анализа временных рядов и дальнейших исследований в этой области.

1. Каширина Е. А., Курганов А. Н. Нейронные сети как инструмент прогнозирования динамики рыночных цен // Science Time. – 2015. – №12 (24). – Режим доступа: <https://cyberleninka.ru/article/n/neyronnye-seti-kak-instrument-prognozirovaniya-dinamiki-rynochnyh-tsen>. – Дата доступа: 18.10.2022.
2. PRIP 2019 Program May 15, 2019 [Electronic resource]. – Mode of access: [https://prip.bsuir.by/m/12\\_126980\\_0\\_136658.pdf](https://prip.bsuir.by/m/12_126980_0_136658.pdf). – Date of access: 18.10.2022.