

## 165. ГИБРИДНЫЕ МОДЕЛИ НА БАЗЕ LSTM И РАЗЛОЖЕНИЯ ВРЕМЕННЫХ РЯДОВ ДЛЯ МНОГОШАГОВОГО ПРОГНОЗИРОВАНИЯ ВАЛЮТНЫХ РЫНКОВ

*Яковлев Н.Е., Матюшев Е.Ю., студенты гр. 377901*

*Белорусский государственный университет информатики и радиоэлектроники  
г. Минск, Республика Беларусь*

*Федосенко В.А. – канд. технических наук, доцент каф. ЭИ*

Аннотация: В данной работе рассматривается задача многошагового прогнозирования курса доллара США к белорусскому рублю на основе гибридных моделей, сочетающих нейронные сети и методы разложения временных рядов. Использование таких подходов позволяет повысить точность прогнозирования за счёт предварительного выделения тренда, сезонности и шумовой составляющей.

Одним из наиболее эффективных инструментов для анализа временных рядов являются рекуррентные нейронные сети, в частности архитектура LSTM (Long Short-Term Memory) [1].

LSTM-сети предназначены для обработки последовательных данных и способны учитывать долгосрочные зависимости за счёт использования специальной структуры ячеек памяти. В отличие от классических RNN, LSTM решает проблему затухающего градиента.

Основной элемент LSTM — ячейка памяти, включающая три типа ворот:

- входные (input gate);
- забывающие (forget gate);
- выходные (output gate).

Математически работа LSTM описывается следующими уравнениями:

$$\begin{cases} f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \\ i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\ \tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \\ C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \\ o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \\ h_t = o_t \cdot \tanh(C_t) \end{cases} \quad (1),$$

где  $x_t$  — вход в момент времени  $t$ ;  $h_t$  — скрытое состояние;  $C_t$  — состояние ячейки памяти;  $f_t$ ,  $i_t$ ,  $o_t$  — векторы forget, input и output gate соответственно;  $\tilde{C}_t$  — кандидат на обновление состояния;  $W$ ,  $b$  — параметры модели (веса и смещения);  $\sigma$  — сигмоидальная функция активации;  $\tanh$  — гиперболический тангенс [2].

LSTM — разновидность рекуррентных нейронных сетей, предназначенная для работы с последовательными данными. За счёт ячеек памяти и системы управляющих ворот модель эффективно решает проблему затухающего градиента и позволяет моделировать сложные нелинейные зависимости, характерные для финансовых временных рядов.

STL+LSTM основана на предварительном разложении временного ряда методом STL, который выделяет трендовую, сезонную и остаточную компоненты. Каждая компонента прогнозируется отдельно с помощью LSTM, после чего результаты суммируются, что позволяет снизить влияние шума и повысить точность прогнозирования.

EMD-LSTM использует эмпирическое модальное разложение (EMD), представляющее временной ряд в виде набора внутренних мод (IMF), отражающих колебания различных частот. Каждая компонента моделируется отдельной LSTM, а итоговый прогноз формируется путём их агрегации.

CNN-LSTM — гибридная архитектура, в которой сверточные слои извлекают локальные признаки и краткосрочные закономерности, а LSTM моделирует временную динамику. Такая комбинация позволяет учитывать как пространственные, так и временные зависимости. Она особенно эффективна при работе с последовательными данными, где важно распознавать паттерны на разных масштабах времени.

EMD-CNN-LSTM сочетает методы разложения и глубокого обучения: на первом этапе EMD выделяет компоненты, затем для каждой из них CNN извлекает признаки, а LSTM выполняет прогнозирование. Данный подход направлен на обработку шумных и нестационарных временных

рядов. Он позволяет эффективно разделять сложные колебания сигнала на более простые моды, улучшая качество предсказаний. Кроме того, комбинация сверточных и рекуррентных сетей обеспечивает захват как локальных, так и долгосрочных зависимостей во временных данных.

Для анализа использованы ежедневные значения курса USD/BYN за период с 25.01.2016 по 22.01.2026 гг. (таблица 1). Данный временной ряд репрезентативен, так как отражает долгосрочные тренды и краткосрочную волатильность рынка, что позволяет корректно оценить качество моделей многошагового прогнозирования [3].

Таблица 1 – Статистические данные за 2016-2026 года

| Дата       | Курс доллара США к белорусскому рублю |
|------------|---------------------------------------|
| 25.01.2016 | 2.0950                                |
| 26.01.2016 | 2.1100                                |
| 27.01.2016 | 2.1375                                |
| .....      | .....                                 |
| 19.01.2026 | 2.8963                                |
| 21.01.2026 | 2.8712                                |
| 22.01.2026 | 2.8368                                |

Для объективной оценки предложенных архитектур проведено сравнительное исследование на горизонте многошагового прогнозирования пары USD/BYN. В качестве бенчмарков использованы базовая модель LSTM и гибридные подходы с различными методами декомпозиции (STL, EEMD, CEEMDAN) и предикторами (LSTM, CNN-LSTM). Качество оценивалось по метрикам MAE, RMSE и MAPE. Результаты (таблица 2) подтверждают определяющее влияние метода разложения на итоговую точность прогноза.

Таблица 2 – Сравнение эффективности гибридных моделей прогнозирования курса USD/BYN

| Модель           | MAE<br>(BYN) | RMSE<br>(BYN) | MAPE<br>(BYN) |
|------------------|--------------|---------------|---------------|
| LSTM             | 0.0306       | 0.0582        | 0.97          |
| STL+LSTM         | 0.0097       | 0.0210        | 0.30          |
| CNN-<br>LSTM     | 0.0255       | 0.0583        | 0.83          |
| EMD-<br>LSTM     | 0.2336       | 0.2531        | 7.10          |
| EMD-CNN-<br>LSTM | 0.0910       | 0.1073        | 2.82          |

Эксперимент подтвердил, что точность прогноза критически зависит от метода декомпозиции. Модель STL+LSTM показала лучший результат (MAPE 0,30%), тогда как адаптивные EMD-методы оказались малоэффективны (ошибка до 8,26%). Усложнение архитектуры слоями CNN дало лишь незначительный прирост. Таким образом, решающим фактором успеха стало использование детерминированного STL-разложения, обеспечивающего более стабильную работу с данными [4].

Результаты работы наиболее эффективной архитектуры представлены на рисунке 1. Сопоставление истории, реальных данных за первый квартал 2026 года и прогноза модели STL+LSTM подтверждает ее способность успешно улавливать динамику рынка. За счет STL-декомпозиции минимизировано влияние шума, что обеспечило высокую точность аппроксимации на горизонте трех месяцев. Визуальный анализ подтверждает превосходство гибридного подхода над базовыми конфигурациями.




Рисунок 1 – Результаты прогнозирования курса USD/BYN на 3 месяца 2026 года моделью STL+LSTM

Исследование подтвердило эффективность гибридной архитектуры STL+LSTM для прогнозирования курса USD/BYN на 2026 год. Предварительное выделение тренда и сезонности снизило ошибку до MAPE 0,30%, что превосходит результаты базовых LSTM и EMD-моделей. Визуальное соответствие прогноза реальным данным (рис. 1) позволяет рекомендовать данный подход для анализа волатильных рынков в системах поддержки принятия решений.

**Список использованных источников:**

1. Всё о LSTM: зачем нужна нейронная сеть и как с ней работать [Электронный ресурс]. – Режим доступа: <https://sysblok.ru/knowhow/mama-myla-lstm-kak-ustroeny-rekurrentnye-nejroseti-s-dolgoj-kratkosrochnoj-pamjatju/>
2. Мама мыла LSTM: как устроены рекуррентные нейросети с долгой краткосрочной памятью [Электронный ресурс]. – Режим доступа: <https://www.belstat.gov.by/ofitsialnaya-statistika/realny-sektorekonomiki>
3. Курсы валют в банках Беларуси в 2016 [Электронный ресурс]. – Режим доступа: [https://bankchart.by/spravochniki/archive\\_kursov\\_valyut/2016](https://bankchart.by/spravochniki/archive_kursov_valyut/2016)
4. LSTM — PyTorch 2.11 documentation [Электронный ресурс]. – Режим доступа: <https://docs.pytorch.org/docs/stable/generated/torch.nn.LSTM.html>