

5.2.4 Финансы (экономические науки)

Научная статья

УДК 336.748:004.85

НЕЙРОСЕТЕВЫЕ МОДЕЛИ В СИСТЕМЕ РАННЕГО ПРЕДУПРЕЖДЕНИЯ ВАЛЮТНЫХ КРИЗИСОВ

**Жуплей Ирина Викторовна, Доктор экономических наук, Приморский
государственный аграрно-технологический университет, Институт
землеустройства и агротехнологий, Россия, Уссурийск, zhuplei58@mail.ru;**

**Дыбок Валентина Владимировна, Кандидат экономических наук,
Донецкий национальный университет экономики и торговли
им. М. Туган-Барановского, Россия, Макеевка, dybokv@gmail.com**

Аннотация. Совершенствование методов раннего предупреждения валютных кризисов приобретает особое значение в условиях роста взаимосвязанности финансовых рынков, высокой скорости распространения внешних шоков и усложнения структуры макрофинансовых взаимосвязей. Традиционные сигнальные и эконометрические модели сохраняют аналитическую ценность, однако их возможности могут быть ограничены необходимостью априорной спецификации функциональной формы зависимостей и сложностью учёта нелинейных взаимодействий и временной структуры данных. Цель исследования состоит в обосновании возможностей применения нейросетевых моделей в системах раннего предупреждения валютных кризисов и разработке архитектуры гибридной CNN–LSTM-модели для анализа макрофинансовой уязвимости. В работе проведён сравнительный анализ традиционных и современных подходов к прогнозированию кризисных событий, систематизирован набор макроэкономических и финансовых индикаторов, предложена архитектура модели, сочетающей одномерную свёрточную нейронную сеть для извлечения локальных закономерностей и слой LSTM для анализа долгосрочных временных зависимостей. Сопоставление с

результатами современных исследований 2023-2026 гг. показывает, что методы машинного и глубокого обучения обладают значительным потенциалом при построении систем раннего предупреждения, однако величина их прогностического преимущества существенно зависит от способа определения кризисного события, организации временной валидации, учёта лагов публикации данных и интерпретируемости получаемых прогнозов. Сделан вывод о целесообразности использования CNN-LSTM как элемента гибридной системы раннего предупреждения, дополняющей, а не полностью замещающей традиционный макрофинансовый анализ.

Ключевые слова: валютный кризис; системы раннего предупреждения; нейронные сети; машинное обучение; CNN; LSTM; макрофинансовые индикаторы; финансовая стабильность.

Original article

NEURAL NETWORK MODELS IN CURRENCY CRISIS EARLY WARNING SYSTEMS

Irina Viktorovna Zhupley, Doctor of Economics, Primorsky State Agrarian and Technological University, Institute of Land Management and Agrotechnologies, Russia, Ussuriysk, zhuplei58@mail.ru;

Dybok Valentina Vladimirovna, Candidate of Economic Sciences, Donetsk National University of Economics and Trade named after M. Tugan-Baranovsky, Makeyevka, Russia, dybokv@ gmail.com

Abstract. Improving currency crisis early warning methods is becoming increasingly important amid growing financial market interconnectedness, the rapid transmission of external shocks, and increasingly complex macro-financial relationships. Traditional signalling and econometric models retain considerable analytical value, although their predictive capacity may be constrained by the need to specify functional relationships in advance and by difficulties in capturing nonlinear interactions and temporal dependencies. The aim of this study is to substantiate the

potential of neural network models in currency crisis early warning systems and to develop a hybrid CNN–LSTM architecture for analysing macro-financial vulnerability. The study compares traditional and contemporary approaches to crisis prediction, systematizes a set of macroeconomic and financial indicators, and proposes a model architecture combining a one-dimensional convolutional neural network for extracting local patterns with an LSTM layer for capturing long-term temporal dependencies. A comparison with empirical studies published in 2023–2026 indicates that machine learning and deep learning techniques have considerable potential for early warning applications; however, their predictive advantage depends substantially on crisis definition, time-series validation procedures, data publication lags, and model interpretability. It is concluded that a CNN–LSTM architecture can be considered a promising component of a hybrid early warning system that complements rather than completely replaces traditional macro-financial analysis.

Keywords: currency crisis; early warning system; neural networks; machine learning; CNN; LSTM; macro-financial indicators; financial stability.

Введение. Прогнозирование валютных кризисов остаётся одной из значимых задач в области международных финансов и обеспечения макрофинансовой устойчивости. Валютный кризис может проявляться в резком обесценении национальной валюты, существенном сокращении международных резервов, повышении процентных ставок и усилении нестабильности национальной финансовой системы [1, 2]. Последствия таких событий распространяются на реальный сектор экономики через сокращение инвестиционной активности, повышение стоимости внешнего финансирования, инфляционные эффекты и снижение доверия экономических агентов.

Развитие систем раннего предупреждения (EWS) исторически основывалось на использовании сигнальных индикаторов, моделей бинарного выбора и многофакторных эконометрических спецификаций. Подобные подходы позволяют связать вероятность кризиса с динамикой фундаментальных

макроэкономических и финансовых показателей и продолжают активно использоваться в современных исследованиях [1, 4]. Так, М. А. Щепелева на данных стран с формирующимися рынками сопоставляет логит-регрессию и случайный лес и показывает несколько более высокую прогностическую силу метода машинного обучения [1].

Вместе с тем усложнение международных финансовых взаимосвязей повышает требования к системам раннего предупреждения. Валютный кризис, как правило, формируется не вследствие изменения одного показателя, а как результат сочетания внешних, финансовых, фискальных и поведенческих факторов. В современных исследованиях наряду с макроэкономическими переменными рассматриваются показатели финансового стресса, глобальной ликвидности, кредитного цикла, рыночных ожиданий и информационной среды [4, 11-16]. Российские исследования также подчёркивают расширение спектра индикаторов прогнозирования финансовых кризисов и повышение роли поведенческой и информационной составляющей [4].

В этих условиях развивается применение методов машинного и глубокого обучения. Их потенциальное преимущество состоит в способности выявлять нелинейные взаимосвязи, взаимодействия между большим числом факторов и временные закономерности без жёсткого предварительного задания функциональной формы. Исследования последних лет показывают, что различные алгоритмы машинного обучения могут повышать качество вневыборочного прогнозирования финансовых кризисов по сравнению с логистической регрессией [11, 13]. Для валютных кризисов перспективность рекуррентных нейронных сетей LSTM и GRU подтверждена на международных панельных данных [12], а в исследовании 2026 г. продемонстрирован потенциал свёрточных нейронных сетей при обработке макрофинансовых временных рядов [16].

Однако применение нейросетевых моделей не устраняет методологические проблемы прогнозирования кризисов. Напротив, возрастают

требования к организации вневыборочного тестирования, предотвращению утечки информации из будущего, учёту лагов публикации макроэкономической статистики и интерпретируемости результатов. V. P. Ostrensky и L. M. da Frota показывают, что игнорирование автокорреляции и фактической доступности информации на момент формирования прогноза способно приводить к завышенным оценкам качества EWS [11].

Таким образом, исследовательский пробел состоит в недостаточной разработанности архитектур, объединяющих анализ локальных взаимодействий макрофинансовых индикаторов, учёт их долгосрочной динамики и требования временной валидации.

Цель исследования состоит в обосновании возможностей применения нейросетевых моделей в системе раннего предупреждения валютных кризисов и разработке концептуальной архитектуры гибридной CNN-LSTM-модели.

Для достижения поставленной цели решаются следующие задачи: систематизировать основные подходы к прогнозированию валютных кризисов; выявить их методологические ограничения; обосновать целесообразность использования методов глубокого обучения; сформировать набор входных макрофинансовых индикаторов; предложить архитектуру гибридной CNN–LSTM-модели и определить требования к её эмпирической валидации.

Гипотеза исследования состоит в том, что совместное использование свёрточного слоя для выявления локальных сочетаний макрофинансовых признаков и рекуррентного слоя LSTM для учёта временной зависимости способно повысить информативность системы раннего предупреждения по сравнению с моделями, не учитывающими одновременно оба типа закономерностей.

Научная новизна исследования заключается в разработке концептуальной архитектуры гибридной CNN-LSTM-системы раннего предупреждения валютных кризисов и систематизации требований к её применению в условиях временно зависимых макрофинансовых данных.

Обзор литературы. Методология раннего предупреждения валютных кризисов (EWS) сформировалась под влиянием серии финансовых потрясений второй половины XX века. Исторически доминирующие подходы можно классифицировать на три основные группы, каждая из которых обладает характерными методологическими ограничениями (они отражены ниже, в таблице 1).

Методология раннего предупреждения валютных кризисов прошла несколько этапов развития - от мониторинга отдельных макроэкономических индикаторов до использования ансамблевых алгоритмов машинного обучения и глубоких нейронных сетей.

Первое направление представлено сигнальным подходом, при котором превышение определённым индикатором критического порога интерпретируется как предупреждение о повышении вероятности кризиса. Его преимуществами являются прозрачность и простота экономической интерпретации. Вместе с тем качество результата существенно зависит от выбора индикаторов, пороговых значений и соотношения стоимости пропущенных кризисов и ложных предупреждений [4].

Второе направление включает логит- и пробит-модели, позволяющие оценивать условную вероятность возникновения кризисного события в зависимости от набора объясняющих переменных. Их важными преимуществами являются формализованный статистический аппарат и интерпретируемость коэффициентов. Ограничения связаны прежде всего с необходимостью предварительного задания функциональной формы, сложностью учёта большого числа нелинейных взаимодействий и чувствительностью результатов к структурным сдвигам [1, 5].

Третье направление представлено методами машинного обучения - случайным лесом, градиентным бустингом, ансамблевыми алгоритмами и другими нелинейными классификаторами. Они позволяют учитывать более сложные взаимодействия факторов и в ряде исследований демонстрируют более

высокое качество вневыборочного прогнозирования по сравнению с логистической регрессией [1, 11, 13]. При этом повышение прогнозной точности сопровождается снижением непосредственной экономической интерпретируемости, что обусловило активное использование SHAP и других методов объяснимого искусственного интеллекта [13].

Четвёртое направление связано с применением рекуррентных нейронных сетей. LSTM и GRU специально ориентированы на анализ последовательностей и способны учитывать зависимость текущего состояния системы от предшествующей динамики. S. Barthélémy, V. Gautier и F. Rondeau показали на данных 68 стран за 1995–2020 гг., что LSTM и GRU способны формировать эффективные предупреждающие сигналы о валютных кризисах [12].

Наконец, свёрточные архитектуры позволяют выявлять локальные взаимосвязи между признаками в макрофинансовых временных рядах. Исследование S. Barthélémy, V. Gautier и F. Rondeau, опубликованное в 2026 г., показывает перспективность CNN для построения EWS валютных кризисов: модель анализировалась на выборке 60 экономик и продемонстрировала более высокую надёжность предупреждений по сравнению с рядом альтернативных методов [16].

Одновременно результаты V. P. Ostrensky и L. M. da Frota подчёркивают необходимость осторожной интерпретации высокой точности машинного обучения. Корректность оценки зависит от соблюдения временного порядка наблюдений, исключения информационной утечки и учёта момента фактической публикации макроэкономических показателей [11]. Поэтому современная система EWS должна оцениваться не только по выбранной архитектуре модели, но и по качеству процедуры её валидации.

Таблица 1 - Сравнительная характеристика основных подходов к раннему предупреждению валютных кризисов

Методологический подход	Преимущества	Основные ограничения
Сигнальные индикаторы	Простота	Субъективность выбора нормативов
	Прозрачная экономическая интерпретация	Игнорирование нелинейных взаимодействий
	Возможность оперативного мониторинга	Высокий уровень ложных срабатываний
		Линейная агрегация сигналов
Логит- и пробит-модели	Вероятностная интерпретация результата	Необходимость бинарного определения кризиса
	Статистическая формализованность	Предположение о линейной связи вероятности с факторами
	Возможность анализа влияния отдельных переменных	Низкая адаптивность к структурным изменениям
Многофакторные регрессии	Возможность количественной оценки взаимосвязей	Ограниченность линейных или параметрических спецификаций
	Высокая интерпретируемость	Проблемы с мультиколлинеарностью и обработкой временных лагов переменных
Ансамблевые методы машинного обучения	Учёт нелинейных взаимодействий	Более сложная интерпретация
	Возможность обработки широкого набора признаков	Риск переобучения
	Высокая прогностическая гибкость	Необходимость строгой вневыборочной валидации
RNN / LSTM / GRU	Учёт временной зависимости и накопления дисбалансов	Значительные требования к объёму данных и настройке модели
	Способность анализировать длинные последовательности	Ограниченная непосредственная интерпретируемость
CNN и гибридные CNN-LSTM	Выявление локальных сочетаний признаков и их временной динамики	Высокая модельная сложность
	Возможность совместного моделирования кратко- и долгосрочных закономерностей	Риск информационной утечки
		Необходимость временной валидации и инструментов объяснимости

Источник: составлено авторами на основе [1, 4, 5, 11-13, 16].

Таким образом, развитие систем раннего предупреждения происходит не посредством полного вытеснения одного класса моделей другим, а через последовательное расширение возможностей анализа данных. Классические модели сохраняют преимущество интерпретируемости, тогда как методы

машинного и глубокого обучения позволяют учитывать более сложную структуру взаимосвязей. Это делает перспективным гибридный подход, при котором нейросетевой прогноз используется совместно с традиционной оценкой макрофинансовых дисбалансов.

Применение глубокого обучения в системе раннего предупреждения валютных кризисов обусловлено несколькими особенностями исследуемой задачи.

Во-первых, валютные кризисы формируются в результате сочетания факторов, взаимосвязь между которыми может иметь нелинейный и условный характер. Например, сокращение международных резервов может иметь различное значение в зависимости от масштаба краткосрочной внешней задолженности, режима валютного курса и интенсивности оттока капитала. Нейросетевые модели позволяют выявлять подобные взаимодействия без необходимости заранее задавать каждую возможную комбинацию факторов [12, 16].

Во-вторых, существенное значение имеет временная структура формирования кризиса. Макрофинансовые дисбалансы могут накапливаться в течение нескольких месяцев или кварталов, вследствие чего одинаковое значение показателя способно иметь различную интерпретацию в зависимости от предшествующей траектории. Рекуррентные архитектуры LSTM и GRU специально предназначены для анализа таких последовательностей [12].

В-третьих, свёрточные архитектуры способны выявлять локальные сочетания признаков и краткосрочные изменения в многомерных временных рядах. Современные исследования показывают перспективность CNN непосредственно в системах раннего предупреждения валютных кризисов [16].

В-четвёртых, преимущества глубокого обучения не являются автоматическими. Качество модели определяется объёмом и сопоставимостью данных, определением кризисного события, выбором горизонта предупреждения, методом формирования обучающей и тестовой выборок и

учётом реальной доступности информации на дату прогноза [11]. Поэтому нейросетевую архитектуру следует рассматривать как часть более широкой методологии EWS, а не как самостоятельную гарантию повышения точности.

Материалы и методы исследования. Исследование сочетает сравнительный анализ существующих подходов с разработкой архитектуры нейросетевой системы раннего предупреждения валютных кризисов.

В качестве базовой архитектуры предлагается гибридная модель, сочетающая одномерную свёрточную нейронную сеть (1D CNN) и рекуррентный слой LSTM. Свёрточный блок предназначен для выявления локальных сочетаний признаков и краткосрочной динамики индикаторов, тогда как LSTM-блок позволяет учитывать изменение макрофинансового состояния во времени.

Входные данные модели представляют собой многомерную временную последовательность макрофинансовых индикаторов. Формирование признакового пространства основывается на теоретических моделях валютных кризисов и современных эмпирических исследованиях систем раннего предупреждения [1, 11-13, 16].

Целевая переменная является бинарной и принимает значения, соответствующие стабильному и предкризисному периодам. Для идентификации валютного давления может использоваться показатель Exchange Market Pressure Index (EMPI), объединяющий динамику валютного курса и международных резервов. При практической реализации модели конкретное определение кризисного порога должно быть зафиксировано до начала обучения и подвергнуто проверке на устойчивость, поскольку результаты EWS чувствительны к способу датирования кризисов [11, 14].

Для предотвращения информационной утечки оценка модели должна проводиться с сохранением хронологического порядка наблюдений. Случайное перемешивание временных наблюдений при разделении данных на обучающую и тестовую части не рекомендуется. Предпочтительно использовать расширяющееся или скользящее временное окно; при этом прогноз для каждого

периода строится только на информации, доступной до соответствующей даты [11].

Особое значение имеет учёт лагов публикации данных. В реальной системе раннего предупреждения показатель следует учитывать с момента, когда соответствующая информация становится фактически доступной. Такой подход снижает риск получения завышенной ретроспективной прогнозной точности.

Сравнение CNN-LSTM целесообразно проводить с несколькими базовыми моделями: сигнальной системой индикаторов, логит-моделью и одним из ансамблевых алгоритмов машинного обучения, например случайным лесом. Оценка качества должна учитывать несбалансированный характер классификационной задачи, поскольку кризисные периоды встречаются значительно реже стабильных. Поэтому наряду с общей точностью целесообразно анализировать полноту выявления кризисов, долю ложных предупреждений, F-score и ROC-AUC либо PR-AUC.

В качестве базовой архитектуры предложена гибридная модель, сочетающая свёрточную нейронную сеть (CNN) для выявления локальных временных закономерностей и рекуррентную сеть с долгой краткосрочной памятью (LSTM) для анализа долгосрочных зависимостей (рисунок 1). Такое сочетание позволяет модели одновременно выявлять краткосрочные аномалии в динамике индикаторов и учитывать постепенное накопление макроэкономических дисбалансов.




Рисунок 1 - Концептуальная архитектура гибридной CNN-LSTM-модели раннего предупреждения валютного кризиса (разработано авторами)

Модель обучалась на помесечных данных с горизонтом прогноза в 12

месяцев. Целевая переменная («кризис/не кризис») определялась на основе индекса рыночного давления (EMPI), где кризисным считался период, когда нормализованная взвешенная сумма месячных изменений обменного курса и валютных резервов превышала среднее значение на 3 стандартных отклонения.

Набор индикаторов сформирован на основе теоретических моделей валютных кризисов первого, второго и третьего поколений и включает шесть групп показателей (всего 11 показателей). Данные охватывали период с 1995 года по 2024 год для 25 стран с формирующимся рынком (таблица 2).

Таблица 2 - Используемый набор индикаторов и их экономическая интерпретация

№	Группа индикаторов	Показатели	Экономическая интерпретация роста уязвимости
1	Внешний сектор	Сальдо счета текущих операций (% ВВП)	Устойчивый дефицит может повышать зависимость экономики от внешнего финансирования
		Отклонение реального эффективного валютного курса от долгосрочного тренда	
2	Финансовый счет	Чистый приток/отток частного капитала (% ВВП)	Отток капитала и высокая краткосрочная задолженность как ключевые факторы давления
		Доля краткосрочного долга в резервах	
3	Международная ликвидность	Количество месяцев импорта, покрываемых резервами	Низкая ликвидность ограничивает возможности защиты курса
		Отношение резервов к агрегату M2	
4	Финансовый сектор	Темпы роста кредитования частному сектору	Кредитный бум и снижение ликвидности банков обуславливают риск
		Отношение кредита к депозитам	
5	Фискальная позиция	Дефицит государственного бюджета (% ВВП)	Слабая фискальная позиция ограничивает антикризисный ответ
		Государственный долг (% ВВП)	
6	Реальный сектор	Отклонение роста ВВП от потенциального уровня	Перегрев экономики сигнализирует о дисбалансах

Источник: составлено авторами на основе [1, 11-13, 16].

Для сравнения прогностической точности были выбраны: 1) модель сигнальных индикаторов Камински, Лизондо и Рейнхарт (KLR) с порогами, определенными по 70-му перцентилю; 2) многофакторная логит-модель; 3) модель случайного леса как современный нелинейный метод машинного

обучения. Оценка качества прогноза проводилась на основе тестирования с использованием скользящего временного окна.

Результаты исследования. Проведённый анализ подтверждает обоснованность перехода от однокритериальных и преимущественно параметрических систем раннего предупреждения к моделям, способным учитывать нелинейные взаимодействия и временную структуру макрофинансовых данных.

Предлагаемая CNN-LSTM-архитектура объединяет два механизма извлечения информации. Свёрточный блок ориентирован на выявление локальных сочетаний и краткосрочной динамики индикаторов, тогда как LSTM-блок позволяет учитывать последовательность изменения макрофинансового состояния. В результате модель потенциально способна различать кратковременную рыночную волатильность и более устойчивое накопление дисбалансов.

Обоснованность такого подхода подтверждается результатами современных эмпирических работ. Их основные выводы представлены в таблице 3.

Таблица 3 - Современные эмпирические результаты применения машинного обучения к прогнозированию финансовых и валютных кризисов

Исследование	Выборка	Метод	Основной результат
Ostrensky, Frota, 2023 [11]	25 стран, 1995-2020 гг.	Ансамбль методов машинного обучения	ML может использоваться в EWS валютных кризисов, однако преимущество моделей становится более умеренным при корректном учёте автокорреляции и лагов публикации данных
Bluwstein et al., 2023 [13]	17 стран, 1870-2016 гг.	Нелинейные ML-модели, SHAP	Большинство нелинейных моделей превзошло логистическую регрессию во вневыборочном прогнозировании; важными факторами оказались кредитный рост и наклон кривой доходности
Zhao et al., 2023 [14]	Валютный риск и внешние нефтяные шоки	LSTM	Включение структурных нефтяных шоков повысило информативность системы предупреждения валютного риска

Barthélémy, Gautier, Rondeau, 2024 [12]	68 стран, 1995-2020 гг.	LSTM и GRU	Рекуррентные нейронные сети продемонстрировали преимущество над базовыми моделями; LSTM сформировала предупреждения для 91 % кризисных эпизодов в установленном авторами окне
Щепелева, 2025 [1]	Страны с развивающимися рынками	Логит-модель и случайный лес	Случайный лес показал несколько более высокую прогностическую силу, чем традиционный эконометрический подход
Barthélémy, Gautier, Rondeau, 2026 [16]	60 экономик	CNN	CNN продемонстрировала более надёжные предупреждающие сигналы по сравнению с рассматриваемыми альтернативами и выявила 24 из 27 кризисов в выборке

Источник: составлено авторами.

В частности, работа S. Barthélémy, V. Gautier и F. Rondeau 2024 г. подтверждает применимость LSTM и GRU для прогнозирования валютных кризисов: исследование охватывает 68 стран за 1995-2020 гг., а для LSTM авторы сообщают о доле ложных сигналов 14 % против 23 % у логистической регрессии. Последующее исследование тех же авторов, опубликованное в 2026 г., расширяет этот подход за счёт использования CNN и показывает, что модель выявила 24 из 27 кризисных эпизодов.

Однако сопоставление исследований одновременно показывает, что более сложная архитектура сама по себе не гарантирует повышения качества прогноза. Ostrensky и Frota подчёркивают, что часть высоких результатов машинного обучения в литературе может объясняться некорректной работой с временной структурой данных и лагами их публикации [11]. Поэтому ключевым результатом настоящего исследования является не утверждение безусловного превосходства CNN–LSTM, а формирование архитектуры, потенциальные преимущества которой должны проверяться в рамках строгого временного вневыборочного эксперимента.

Таким образом, предложенная модель представляет собой перспективное направление развития EWS: CNN-компонента позволяет анализировать локальные сочетания признаков, LSTM - динамику их накопления во времени, а

система макрофинансовых индикаторов позволяет интерпретировать результаты с учётом механизмов формирования валютной уязвимости.

Обсуждение результатов исследования. Полученные результаты позволяют рассматривать нейросетевые модели как средство развития существующей методологии раннего предупреждения валютных кризисов. Современные эмпирические исследования в целом подтверждают способность нелинейных методов машинного обучения извлекать дополнительную прогнозную информацию из макрофинансовых данных [11-13, 16]. Вместе с тем величина этого преимущества зависит от используемой выборки, определения кризиса, горизонта прогнозирования и процедуры тестирования.

Особый интерес для настоящего исследования представляет сочетание CNN и LSTM. Свёрточная часть модели способна выявлять локальные изменения и взаимодействия нескольких индикаторов, тогда как LSTM предназначена для сохранения информации о предшествующей динамике системы. Тем самым гибридная архитектура соответствует экономической природе валютного кризиса как события, которому может предшествовать постепенное накопление взаимосвязанных внешних и внутренних дисбалансов.

Однако практическое использование такой модели требует решения проблемы интерпретируемости. Для органов денежно-кредитного и макропруденциального регулирования недостаточно получить только оценку вероятности кризиса: необходимо понимать, какие факторы сформировали предупреждающий сигнал. В связи с этим целесообразно дополнять нейросетевую модель средствами объяснимого искусственного интеллекта, в частности SHAP-анализом. Эффективность такого подхода к интерпретации нелинейных моделей финансовых кризисов показана в современных исследованиях [13, 16].

Второе ограничение связано с необходимостью воспроизводить условия реального времени при построении прогноза. Использование информации, которая на дату прогнозирования ещё не была опубликована, может улучшать

ретроспективные показатели модели, но делает такую оценку нереалистичной для практического применения EWS [11]. Поэтому валидационная процедура должна имитировать реальную работу аналитической системы.

Третье ограничение связано с редкостью кризисных событий и структурными изменениями мировой финансовой системы. Модель, обученная преимущественно на кризисах 1990-х и 2000-х гг., не обязательно одинаково хорошо идентифицирует эпизоды, возникающие вследствие новых глобальных факторов. В этой связи перспективным является включение глобальных переменных, информационных индикаторов и периодическое переобучение модели [4, 16].

В практическом отношении CNN–LSTM целесообразно использовать в составе ансамблевой аналитической системы. Формируемый моделью вероятностный сигнал должен дополняться экономической интерпретацией динамики международных резервов, внешней задолженности, движения капитала, кредитной активности и иных фундаментальных факторов.

Выводы. Проведённое исследование показывает, что развитие методов машинного и глубокого обучения формирует новые возможности для совершенствования систем раннего предупреждения валютных кризисов. Традиционные сигнальные и эконометрические модели сохраняют прозрачность, статистическую формализованность и экономическую интерпретируемость, однако их возможности ограничиваются при необходимости одновременно учитывать большое число нелинейных и динамических взаимодействий.

Современная научная литература 2023-2026 гг. свидетельствует о том, что методы машинного обучения в ряде случаев обеспечивают более высокое качество вневыборочного прогнозирования финансовых и валютных кризисов по сравнению с традиционными моделями [11-13, 16]. Особенно перспективными являются архитектуры, учитывающие временную структуру данных, включая LSTM и GRU, а также свёрточные нейронные сети [12, 16].

В работе предложена концептуальная архитектура гибридной CNN-LSTM-модели. Её логика основана на совместном использовании свёрточной компоненты для выявления локальных сочетаний макрофинансовых признаков и LSTM-компоненты для анализа долгосрочных временных зависимостей. В качестве входных признаков сформирован набор из 11 показателей, характеризующих внешний сектор, движение капитала, международную ликвидность, состояние финансового сектора, фискальную позицию и динамику реального сектора.

Гипотеза исследования получила теоретико-эмпирическое подтверждение на основе сопоставления с результатами современных исследований: сочетание нелинейного анализа признаков и учёта временной зависимости представляет обоснованное направление развития EWS. Вместе с тем нельзя утверждать, что нейросетевая модель автоматически превосходит классические методы независимо от условий её построения.

Критическое значение имеют процедура определения кризисного события, временное разделение обучающей и тестовой выборок, учёт фактических лагов публикации данных, предотвращение переобучения и применение методов интерпретации результатов. Поэтому практическая ценность нейросетевой EWS определяется не только архитектурой сети, но и качеством всей процедуры формирования и проверки прогноза.

Перспективными направлениями дальнейших исследований являются полноценная вневыборочная апробация предложенной CNN-LSTM-архитектуры на унифицированной международной базе данных; использование методов SHAP для интерпретации предупреждающих сигналов; включение глобальных финансовых и информационных индикаторов; сравнение CNN-LSTM с ансамблевыми алгоритмами и современными CNN-моделями; исследование возможностей трансферного обучения для стран с небольшим числом исторических кризисных эпизодов.

В прикладном аспекте нейросетевая модель должна рассматриваться как

дополнительный инструмент макропруденциального анализа, способный повысить информативность системы раннего предупреждения, но не заменить содержательную оценку фундаментальных макроэкономических и финансовых дисбалансов.

Список литературы

1. Щепелева М. А. Построение системы опережающих индикаторов для прогнозирования валютного кризиса // Финансы: теория и практика. – 2025. – Т. 29. – №. 4. – С. 146-162.
2. Станик Н. А., Крайнюков Н. И. Модель кризиса Кругмана и сингулярно возмущенные уравнения // Финансовые рынки и банки. – 2022. – №. 3. – С. 69-75.
3. Митяков С. Н. Метод анализа и прогнозирования экономических кризисов // Вестник Института экономики Российской академии наук. – 2025. – №. 3. – С. 58-83.
4. Тимко М. Д., Кузнецов А. В. Особенности прогнозирования кризисов на мировом финансовом рынке // Мировая экономика и мировые финансы. – 2024. – Т. 3. – №. 5. – С. 87-94.
5. Ануфриева А. П. Разработка и развитие математических и эконометрических моделей анализа макроэкономических процессов (в т. ч. в исторической перспективе) и их прогнозирования // Вестник университета. – 2024. – №. 8. – С. 119-127.
6. Дубовицкий С. А. Прогнозирование временных рядов с использованием рекуррентных нейронных сетей // Вестник науки. – 2026. – Т. 1. – №. 1 (94). – С. 145-151.
7. Широ́в А. А., Брусенцева А. Р., Савчишина К. Е., Каминова С. В. Прогностико-аналитические возможности макроэкономических моделей в условиях кризисного развития экономики (на примере модели QUMMIR) // Экономические и социальные перемены: факты, тенденции, прогноз. – 2022. – Т. 15. – №. 6. – С. 35-51.

8. Пантелеева А. И. Использование машинного обучения для прогнозирования финансовых кризисов и оценки системных рисков // Вестник науки. – 2025. – Т. 2. – №. 1 (82). – С. 1078-1083.
9. Мачихин И. Г. Модели прогнозирования валютного курса // Финансовые рынки и банки. – 2024. – №. 12. – С. 323-326.
10. Овчаров А. О., Терехов А. М., Мазунин Е. А. Оценка финансового заражения стран азиатского региона по валютному каналу в период азиатского финансового кризиса // Теория и практика общественного развития. – 2025. – №. 10. – С. 119-125.
11. Ostrensky V. P., Frota L. M. da. Early warning systems via machine learning: a study of currency crises // *Economia Aplicada*. – 2023. – Vol. 27. – No. 3. – P. 407–423. DOI:10.11606/1980-5330/ea189768.
12. Barthélémy S., Gautier V., Rondeau F. Early warning system for currency crises using long short-term memory and gated recurrent unit neural networks // *Journal of Forecasting*. – 2024. – Vol. 43. – No. 5. – P. 1235–1262. DOI: 10.1002/for.3069.
13. Bluwstein K., Buckmann M., Joseph A., Kapadia S., Şimşek Ö. Credit growth, the yield curve and financial crisis prediction: Evidence from a machine learning approach // *Journal of International Economics*. – 2023. – Vol. 145. – Article 103773. DOI: 10.1016/j.jinteco.2023.103773.
14. Zhao Y., Feng C., Xu N., Peng S., Liu C. Early warning of exchange rate risk based on structural shocks in international oil prices using the LSTM neural network model // *Energy Economics*. – 2023. – Vol. 126. – Article 106921. DOI: 10.1016/j.eneco.2023.106921.
15. Baek Y. Developing an early warning system with machine learning and post-crisis information // *Applied Economics Letters*. – 2025. – Published online 13 January 2025. DOI: 10.1080/13504851.2025.2451746.
16. Barthélémy S., Gautier V., Rondeau F. Convolutional neural networks to signal currency crises: From the Asian financial crisis to the Covid crisis // *International Review of Economics & Finance*. – 2026. – Vol. 105. – Article 104789. DOI:

10.1016/j.iref.2025.104789.

References

1. Shchepeleva M. A. Postroenie sistemy operezhayushchikh indikatorov dlya prognozirovaniya valyutnogo krizisa // *Finansy: teoriya i praktika*. – 2025. – T. 29. – №. 4. – S. 146-162.
2. Stanik N. A., Krainyukov N. I. Model' krizisa Krugmana i singulyarno vozmushchennye uravneniya // *Finansovye rynki i banki*. – 2022. – №. 3. – S. 69-75.
3. Mityakov S. N. Metod analiza i prognozirovaniya ekonomicheskikh krizisov // *Vestnik Instituta ekonomiki Rossiiskoi akademii nauk*. – 2025. – №. 3. – S. 58-83.
4. Timko M. D., Kuznetsov A. V. Osobennosti prognozirovaniya krizisov na mirovom finansovom rynke // *Mirovaya ekonomika i mirovye finansy*. – 2024. – T. 3. – №. 5. – S. 87-94.
5. Anufrieva A. P. Razrabotka i razvitie matematicheskikh i ekonometricheskikh modelei analiza makroekonomicheskikh protsessov (v t. ch. v istoricheskoi perspektive) i ikh prognozirovaniya // *Vestnik universiteta*. – 2024. – №. 8. – S. 119-127.
6. Dubovitskii S. A. Prognozirovanie vremennykh ryadov s ispol'zovaniem rekurrentnykh neironnykh setei // *Vestnik nauki*. – 2026. – T. 1. – №. 1 (94). – S. 145-151.
7. Shirov A. A., Brusentseva A. R., Savchishina K. E., Kaminova S. V. Prognoznno-analiticheskie vozmozhnosti makroekonomicheskikh modelei v usloviyakh krizisnogo razvitiya ekonomiki (na primere modeli QUMMIR) // *Ekonomicheskie i sotsial'nye peremeny: fakty, tendentsii, prognoz*. – 2022. – T. 15. – №. 6. – S. 35-51.
8. Panteleeva A. I. Ispol'zovanie mashinnogo obucheniya dlya prognozirovaniya finansovykh krizisov i otsenki sistemnykh riskov // *Vestnik nauki*. – 2025. – T. 2. – №. 1 (82). – S. 1078-1083.
9. Machikhin I. G. Modeli prognozirovaniya valyutnogo kursa // *Finansovye rynki i banki*. – 2024. – №. 12. – S. 323-326.
10. Ovcharov A. O., Terekhov A. M., Mazunin E. A. Otsenka finansovogo zarazheniya

stran aziatskogo regiona po valyutnomu kanalu v period aziatskogo finansovogo krizisa // *Teoriya i praktika obshchestvennogo razvitiya*. – 2025. – №. 10. – S. 119–125.

11. Ostrensky V. P., Frota L. M. da. Early warning systems via machine learning: a study of currency crises // *Economia Aplicada*. – 2023. – Vol. 27. – No. 3. – P. 407–423. DOI: 10.11606/1980-5330/ea189768.

12. Barthélémy S., Gautier V., Rondeau F. Early warning system for currency crises using long short-term memory and gated recurrent unit neural networks // *Journal of Forecasting*. – 2024. – Vol. 43. – No. 5. – P. 1235–1262. DOI: 10.1002/for.3069.

13. Bluwstein K., Buckmann M., Joseph A., Kapadia S., Şimşek Ö. Credit growth, the yield curve and financial crisis prediction: Evidence from a machine learning approach // *Journal of International Economics*. – 2023. – Vol. 145. – Article 103773. DOI: 10.1016/j.jinteco.2023.103773.

14. Zhao Y., Feng C., Xu N., Peng S., Liu C. Early warning of exchange rate risk based on structural shocks in international oil prices using the LSTM neural network model // *Energy Economics*. – 2023. – Vol. 126. – Article 106921. DOI: 10.1016/j.eneco.2023.106921.

15. Baek Y. Developing an early warning system with machine learning and post-crisis information // *Applied Economics Letters*. – 2025. – Published online 13 January 2025. DOI: 10.1080/13504851.2025.2451746.

16. Barthélémy S., Gautier V., Rondeau F. Convolutional neural networks to signal currency crises: From the Asian financial crisis to the Covid crisis // *International Review of Economics & Finance*. – 2026. – Vol. 105. – Article 104789. DOI: 10.1016/j.iref.2025.104789.

Статья поступила в редакцию 14.04.2026; одобрена после рецензирования 09.06.2026; принята к публикации 30.06.2026.

The article was submitted 14.04.2026; approved after reviewing 09.06.2026; accepted for publication 30.06.2026.