

# ПРОГНОЗИРОВАНИЕ РИСКОВ С ИСПОЛЬЗОВАНИЕМ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Тимошенко В. А., Бегляк Е. В., Мигалевич С. А.

Центр информатизации и инновационных разработок,

Белорусский государственный университет информатики и радиоэлектроники

Минск, Республика Беларусь

E-mail: {v.timoshenko, katarina, migalevich}@bsuir.by

*Доклад посвящен анализу современных методов прогнозирования рисков с использованием искусственного интеллекта. Рассматриваются вероятностные модели оценки рисков, нейросетевые методы генерации сценариев, алгоритмы машинного обучения для выявления закономерностей и оценка точности прогнозов. Приводятся примеры практического применения технологий ИИ для минимизации финансовых, производственных и технических рисков в различных сферах деятельности.*

## ВВЕДЕНИЕ

Современные организации функционируют в условиях высокой неопределенности, характеризующейся динамичными изменениями внешней среды, технологическим прогрессом и глобальными вызовами. Кризисы финансовых рынков, перебои в цепях поставок, стихийные бедствия и кибератаки подчеркивают необходимость своевременной оценки рисков и разработки сценариев развития событий [1].

Искусственный интеллект (ИИ) открывает новые возможности для анализа больших объемов данных, выявления скрытых закономерностей и автоматизации процесса оценки вероятности различных событий. Использование ИИ позволяет количественно оценивать вероятность наступления неблагоприятных исходов, строить сценарии их развития, анализировать сложные взаимозависимости между факторами и прогнозировать последствия [2].

## I. ВЕРОЯТНОСТНЫЕ МЕТОДЫ ПРОГНОЗИРОВАНИЯ

Вероятностные методы являются фундаментом прогнозирования рисков. Суть подхода заключается в описании риска как случайной величины с заданным распределением вероятностей. Пусть событие риска  $R$  характеризуется случайной величиной  $X$ , отражающей возможный ущерб. Тогда вероятность наступления критического события определяется выражением:

$$P(R) = \mathbb{P}(X \geq X_{\text{critical}}),$$

где  $X_{\text{critical}}$  – пороговое значение ущерба, при превышении которого событие считается значимым [3].

Ожидаемый ущерб (Expected Loss, EL) рассчитывается как сумма произведений вероятностей и соответствующих величин ущерба:

$$EL = \sum_{i=1}^n P(R_i) \cdot L_i,$$

где  $L_i$  – потенциальный ущерб при реализации риска  $R_i$ ,  $P(R_i)$  – вероятность наступления дан-

ного риска. Эти модели позволяют ранжировать риски по значимости и формировать приоритетные меры по их минимизации.

Для повышения точности прогнозов применяются методы Байесовской статистики, которые позволяют обновлять оценки вероятностей по мере поступления новой информации. Временные ряды и модели Markov Chain учитывают динамику факторов риска, обеспечивая прогноз на несколько шагов вперед и моделирование сценариев развития событий [4].

Дополнительно используется метод Монте-Карло, позволяющий моделировать тысячи возможных сценариев и оценивать распределение потерь с учетом редких, но потенциально катастрофических событий [5]. Такой подход применяется в страховании, финансовом секторе и инженерии безопасности.

## II. НЕЙРОСЕТЕВЫЕ МЕТОДЫ И ГЕНЕРАТИВНЫЕ МОДЕЛИ

Современные методы машинного обучения применяются для прогнозирования сложных, многомерных рисков. Генеративные модели, такие как вариационные автоэнкодеры (VAE) и генеративные состязательные сети (GAN), создают новые сценарии на основе исторических данных и случайного шума:

$$\hat{X}_{t+1} = G_\theta(\hat{X}_t, Z_t),$$

где  $\hat{X}_t$  – сгенерированные сценарии на шаге  $t$ ,  $G_\theta$  – генеративная функция с параметрами  $\theta$ ,  $Z_t$  – случайный шум [6].

Генеративные модели позволяют создавать стресс-сценарии, выходящие за рамки наблюдаемых данных, что особенно важно при анализе «черных лебедей» – редких и трудно прогнозируемых событий.

Рекуррентные нейронные сети (RNN) и модели с долгой краткосрочной памятью (LSTM) эффективны для анализа временных рядов, прогнозирования финансовых показателей, выявления сбоев в производственных процессах и мониторинга эксплуатационных рисков. Их преимущество заключается в умении учитывать долгосрочные

зависимости, которые часто играют ключевую роль в системах с накопительным эффектом.

Гибридные методы, объединяющие нейросети с экспертной оценкой и вероятностными моделями, повышают точность прогнозов и устойчивость системы к шуму и неполноте данных. Использование ансамблей моделей снижает влияние случайных ошибок и позволяет строить надежные прогнозы даже при ограниченном объеме данных.

Отдельным направлением является применение графовых нейронных сетей (GNN) для анализа взаимосвязей между элементами сложных систем, например, в цепях поставок или киберфизических системах. Такой подход позволяет моделировать каскадные эффекты и оценивать системные риски.

### III. ОЦЕНКА ТОЧНОСТИ И НАДЕЖНОСТИ МОДЕЛЕЙ

Оценка точности прогнозов является ключевым элементом. Стандартные метрики включают среднеквадратичную ошибку (RMSE):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{X}_i - X_i)^2},$$

а также среднюю абсолютную ошибку (MAE), коэффициент детерминации  $R^2$  и вероятностные интервалы.

Методы кросс-валидации, бутстреппинга и тестирования на отложенной выборке помогают оценивать устойчивость моделей, предотвращать переобучение и гарантировать адекватность прогнозов новым данным. Также важно учитывать неопределенность прогнозов, чтобы управленцы могли принимать решения с вероятностным диапазоном возможных исходов.

### IV. ПРАКТИЧЕСКОЕ ПРИМЕНЕНИЕ

ИИ для прогнозирования рисков используется в финансовой сфере, производстве, энергетике, здравоохранении, логистике и управлении проектами. Автоматизация анализа позволяет:

- выявлять потенциально опасные сценарии и тенденции;
- оценивать влияние отдельных факторов на вероятность ущерба;
- планировать ресурсное обеспечение для снижения вероятности негативных событий;
- создавать комплексные отчеты для руководства и органов контроля;
- адаптировать модели под специфику конкретной организации.

Примеры применения:

В производстве ИИ прогнозирует технические сбои оборудования, выявляет паттерны износа и прогнозирует аварийные ситуации; в финансовой отрасли модели помогают оценивать кредитные, рыночные и операционные риски; в здравоохранении прогнозирование рисков позволяет выявлять кризисные ситуации, планировать ресурсы и оптимизировать процессы оказания помощи [7]; в логистике и управлении цепями поставок ИИ прогнозирует перебои, сбои поставок и повышает устойчивость процессов.

### ЗАКЛЮЧЕНИЕ

Использование ИИ для прогнозирования рисков обеспечивает точную оценку вероятностей, выявление скрытых закономерностей и автоматизацию анализа сложных сценариев. Наиболее перспективны гибридные модели, совмещающие вероятностные методы, генеративные модели и экспертную проверку. Практическая реализация требует качественных данных, прозрачности алгоритмов, регулярного контроля точности прогнозов и непрерывного совершенствования моделей.

Комплексный подход к прогнозированию рисков с использованием ИИ позволяет организациям принимать обоснованные решения, минимизировать потенциальные убытки и адаптироваться к изменяющимся условиям внешней среды, повышает устойчивость и конкурентоспособность.

1. Jorion, P. *Value at Risk: The New Benchmark for Managing Financial Risk*. 3rd ed. McGraw-Hill, 2006. ISBN 978-0071464950. – Дата доступа: 28.09.2025.
2. Goodfellow, I., Pouget-Abadie, J., et al. Generative Adversarial Nets [Electronic resource] // Advances in Neural Information Processing Systems. – 2014. – Mode of access: <https://papers.nips.cc/paper/5423-generative-adversarial-nets.pdf>. – Date of access: 29.09.2025.
3. Hochreiter, S., Schmidhuber, J. Long Short-Term Memory [Electronic resource] // Neural Computation. – 1997. – Mode of access: <https://direct.mit.edu/neco/article/9/8/1735/6109/Long-Short-Term-Memory>. – Date of access: 29.09.2025.
4. Risk.net. Using AI to predict operational risk [Electronic resource] / Risk.net. – London, 2022. – Mode of access: <https://www.risk.net/operational-risk/7802746/using-ai-to-predict-operational-risk>. – Date of access: 30.09.2025.
5. Shreve, S. *Stochastic Calculus for Finance II: Continuous-Time Models*. Springer, 2004. ISBN 0387401016. – Date of access: 30.09.2025.
6. Battiston, S., Farmer, J. D., et al. Financial networks and systemic risk [Electronic resource] // Science. – 2016. – Vol. 351, no. 6274. – P. 818–819. – Mode of access: <https://www.science.org/doi/10.1126/science.aad0299>. – Date of access: 01.10.2025.
7. Miotto, R., Wang, F., et al. Deep learning for healthcare: review, opportunities and challenges [Electronic resource] // Briefings in Bioinformatics. – 2018. – Vol. 19, no. 6. – P. 1236–1246. – Mode of access: <https://academic.oup.com/bib/article/19/6/1236/4102709>. – Date of access: 01.10.2025.