

# Математическое моделирование и прогнозирование финансового состояния кредитных организаций

Иванов В.В.<sup>1</sup>, Приказчикова А.С.<sup>2</sup>

<sup>1</sup>Объединенный институт ядерных исследований, ул. Жолио-Кюри, д. 6, г. Дубна, 141980, Россия.

<sup>2</sup>Национальный исследовательский ядерный университет «МИФИ», Каширское шоссе, д. 31, г. Москва, 115409, Россия

ivanov@jinr.ru, aska4.92@mail.ru

**Аннотация.** Целью настоящего исследования является развитие новых подходов для оценки и прогнозирования финансового состояния кредитных организаций России в соответствии с государственным заказом по созданию цифрового профиля юридического лица, характеризующего его деятельность на основе баз данных государственных органов (Национальная программа «Цифровая экономика Российской Федерации», Указ Президента от 21.07.2020 г. № 474 «О национальных целях развития Российской Федерации на период до 2030 года»). Авторами предложены новые математические модели, методы, алгоритмы и комплексы программ, основанные на искусственных нейронных сетях, статистических методах обработки данных, деревьях и лесах решений, а также на использовании сингулярно-спектрального анализа. В результате комплексного применения указанных математических инструментов к показателям из стандартной формы банковской отчетности № 101 удалось провести всестороннюю оценку и прогноз финансового состояния действующих на сегодняшний день в России кредитных организаций.

**Ключевые слова:** искусственные нейронные сети, кластерный анализ, метод главных компонент, деревья и леса решений, естественный язык, сингулярно-спектральный анализ в подходе «Гусеница»-SSA, кредитные организации, математическое моделирование, математические методы и алгоритмы

## 1 Введение

Важнейшим условием обеспечения национальной безопасности любой страны является стабильность ее экономической системы. Одним из основных звеньев такой системы является банковский сектор, через который передаются импульсы денежно-кредитного регулирования всей экономике. Устойчивое развитие банковского сектора является первостепенной задачей органов государственного финансового надзора. Для предотвращения возможных кризисов и дефолтов разрабатывается и постоянно совершенствуется комплекс мер, включающий в себя мониторинг, идентификацию, оценку, контроль и прогнозирование возможных рисков. Особое внимание уделяется разработке систем раннего предупреждения, выявляющих склонные к дефолту кредитные организации. Если кредитная организация не исполняет ряд указаний и предписаний, установленных Банком России (ЦБ РФ), или фальсифицирует отчетность, проводит операции, на которые не имеет разрешения; вовлечена в преступную деятельность, ЦБ РФ имеет право аннулировать лицензию у такой организации. Однако чаще всего поводом для отзыва лицензии становится несоблюдение антиотмывочного законодательства – Федерального закона «О противодействии легализации (отмыванию) доходов, полученных преступным путём, и финансированию терроризма» от 07.08.2001 г. № 115-ФЗ [1]. В нашей

стране функции контроля и исполнения данного Федерального закона возложены на Росфинмониторинг.

В своей практике Росфинмониторинг проводит оценку финансового состояния кредитных организаций путем классификации многомерных объектов. Ввиду того, что традиционно в государственных структурах проверка реализуется экспертом вручную, то такой подход является ресурсоемким и ведет к преобладанию экспертного субъективизма. Кроме того, количество объектов, подлежащих оценке, многократно превышает возможности аналитиков. Гетерогенный характер информационных ресурсов и их ежегодно возрастающий объем исключают возможность их ручной обработки.

В связи с чем, задача разработки математических методов, моделей и алгоритмов для оценки и прогнозирования финансового состояния кредитных организаций на основе перехода от экспертных проверок объектов к параллельным массовым автоматизированным проверкам является весьма актуальной в современных реалиях. Ее решение способствует повышению экономической безопасности и стабильности страны, а также удовлетворению потребностей населения в использовании отечественных финансовых услуг. Использование современных вычислительных технологий, позволяющих автоматизировать процесс оценки и прогнозирования обстановки в сфере деятельности кредитных организаций, повысит уровень оперативности получения результатов.

Проведенный авторами анализ существующих методологических подходов к оценке и прогнозированию финансового состояния кредитных организаций показал, что в изученных работах отсутствует комплексный подход к исследованию задачи идентификации высокорисковых кредитных организаций, потенциально вовлеченных в деятельность по легализации преступных денежных средств, возможно, в силу относительной новизны прорабатываемой экономической отрасли.

**Целью настоящей работы** является развитие новых математических моделей, методов, алгоритмов и комплексов программ для оценки и прогнозирования финансового состояния кредитных организаций. Для достижения указанной цели была поставлена **задача** с использованием современных технологий математического моделирования разработать упорядоченную совокупность научно обоснованных технических решений для проведения оценки и прогнозирования финансового состояния кредитных организаций.

В качестве **объекта исследования** выбрано финансовое состояние кредитных организаций, а также показатели их деятельности из стандартной формы банковской отчетности № 101 [2].

**Научная новизна** исследования заключается в разработке комплекса технических решений, внедрение которых в системы раннего предупреждения государственных органов будет способствовать поддержанию ее национальной безопасности и финансовой устойчивости. Автоматизация предложенных математических моделей, методов и алгоритмов позволит аналитически обрабатывать неограниченное количество кредитных организаций и выявлять высокорисковые объекты, подлежащие детальной экспертной проверке.

## 2 Классификация кредитных организаций с помощью искусственных нейронных сетей

На начальном этапе исследования авторами была поставлена задача – предложить новый подход для анализа финансового состояния кредитных с помощью современных технологий математического моделирования – искусственных нейронных сетей (далее – ИНС).

В качестве исходных данных рассматривались показатели 101 формы банковской отчетности «Данные оборотной ведомости по счетам бухгалтерского учета» – 23 показателя о 536 организациях, из которых 202 – неблагонадежные – организации с отозванной лицензией. С целью устранения явления мультиколлинеарности проведен корреляционный анализ исходных показателей. В результате были отобраны только те показатели, для которых не наблюдается сильная корреляционная связь ( $> 0,8$ ) и которые вносят значимый вклад для ИНС – всего 14 показателей. Кроме того, для снижения размерности анализируемого признакового пространства к исходным данным был применен метод главных компонент. Всего отобрано 12 компонент (вместо 23), вклад в общую дисперсию для которых составил 95 % [3].

Анализ моделей ИНС показал, что для рассматриваемой задачи наилучшим образом подходит многослойный перцептрон (МСП). С помощью МСП анализируемые данные разбивались на два класса: благонадежные и неблагонадежные. Для построения моделей ИНС на разных типах данных использовались: пакет прикладных программ Statistica [4] и

программная среда Python [5]. Проведенный анализ результатов моделирования МСП показал, что выбранные архитектуры ИНС обеспечивают приемлемую точность распознавания исследуемых наборов данных. При этом, результаты в Python, с учетом настройки дополнительных параметров, оказались несколько лучше, чем в Statistica.

В таблице 1 представлены значения метрик качества построенных моделей ИНС, сгенерированных в разных программных продуктах на разных типах данных. Из таблицы 1 видно, что полученные модели ИНС имеют высокие значения метрик качества, а значит, могут быть применены для решения практических задач финансового мониторинга. Незначительное отличие значений метрик качества моделей ИНС, рассчитанных в Statistica, от значений метрик качества моделей ИНС, созданных в Python, свидетельствует о сходимости результатов, полученных с использованием альтернативных вычислительных средств [6].

**Таблица 1.** Метрики качества моделей ИНС для разных типов данных.

Метрика качества	Модель ИНС					
	на исходных данных		на некоррелированных показателях		на главных компонентах	
	Statistica	Python	Statistica	Python	Statistica	Python
Precision	68%	77%	62%	68%	57%	72%
Recall	76%	62%	71%	68%	67%	61%
F1-мера	72%	69%	66%	69%	62%	69%
AUC	79%	86%	74%	77%	72%	74%
Accuracy	77%	79%	72%	77%	68%	76%

В целом, можно сделать вывод об эффективности использования ИНС в задаче классификации кредитных организаций, т.к. их применение позволило отобрать существенное количество подозрительных организаций. Однако, в виду их массовости (число организаций, признанных подозрительными составило 34% от общего числа анализируемых объектов) необходимо разработать новые подходы для идентификации объектов повышенного риска, которые необходимо проанализировать в первую очередь. Этому вопросу был посвящен следующий этап данного исследования, в ходе которого на основе метода кластерного анализа  $k$ -средних и метода главных компонент разработана вычислительная схема для идентификации высокорисковых кредитных организаций.

### 3 Прогнозирование попадания кредитных организаций в зону риска

В основе метода  $k$ -средних лежит идея разделения выборки на  $k$  групп таким образом, чтобы минимизировать суммарное квадратичное отклонение точек кластеров от центроидов этих кластеров (1).

$$\min \left[ \sum_{i=1}^k \sum_{x^{(j)} \in S_i} |x^{(j)} - \mu_i|^2 \right], \quad x^{(j)} \in R^n, \quad (1)$$

$\mu_i$  – центроид кластера  $S_i$ ,  $R^n$  – пространство исследуемых объектов [7].

В качестве меры расстояния между точками (наблюдениями) использовалось одно из самых распространенных расстояний – Евклидово расстояние (2):

$$d(x_i, x_j) = \left( \sum_{p=1}^P (x_{ip} - x_{jp})^2 \right)^{1/2}, \quad (2)$$


где  $p = (1, \dots, m)$ ;  $i = (1, \dots, n)$ ,  $x_{ip}$  – величина  $p$ -ой координаты для  $i$ -го объекта,  $x_i = (x_{i1}, x_{i2}, \dots, x_{ip})$  – точка в  $p$ -мерном пространстве [7].

Для корректного применения метода  $k$ -средних использовались разные методы оценки оптимального числа кластеров, на которое необходимо разбить совокупность исходных данных: метод Варда, метод локтя, метод силуэтов, метод Дэвиса-Болдина [8]. Однако, так как использование указанных методов на исходных данных не дало однозначных результатов, к исходной выборке был применен метод главных компонент. В результате, для всех методов оценки оптимального числа кластеров был получен однозначный параметр  $k$ , который

использовался для метода  $k$ -средних.

На следующем шаге проводилась идентификация кластера, содержащего наибольшее количество неблагонадежных организаций, и к нему повторно применялся метод  $k$ -средних. Такая процедура повторялась до тех пор, пока не был найден кластер, содержащий соизмеримое число благонадежных и неблагонадежных объектов. Всего на исходных данных было выполнено пять этапов кластеризации, а в случае главных компонент – шесть.

Далее авторами детально анализировался кластер, полученный на последнем этапе кластерного анализа, а именно, на основе отобранных неблагонадежных организаций строился центроид критической зоны (вектор средних по значениям каждого показателя), а также подсчитывались евклидовы расстояния от центроида до каждого из объектов. Благонадежные организации, расположенные на минимальном евклидовом расстоянии от центроида, были признаны высокорисковыми. На рисунке 1 приведена диаграмма Евклидовых расстояний от центроида зоны риска до всех объектов [8].



**Рис. 1.** Диаграмма Евклидовых расстояний от центроида зоны риска до всех кредитных организаций.

Таким образом, развитая методика позволила: 1) в целом подтвердить результаты, полученные с помощью искусственных нейронных сетей, в зону повышенного риска попало порядка  $5 \div 7$  % организаций от общего количества объектов; 2) оценить вероятность попадания благонадежных организаций в зону повышенного риска. Всего было спрогнозировано  $47 \div 60$  % фактов отзыва банковских лицензий.

#### 4 Разработка математических моделей классификации кредитных организаций с использованием деревьев решений и их ансамблей

На третьем этапе исследования рассмотрена проблема классификации кредитных организаций с использованием моделей дерева решений CART и лесов решений Random Forest, Adaboost и Xgboost и продемонстрирована эффективность их применения для решения поставленной задачи. Приведены правила на естественном языке для идентификации высокорисковых кредитных организаций.

Дерево CART является алгоритмом построения бинарного дерева решений – дихотомической классификационной модели. Алгоритм на каждом шаге построения дерева последовательно сравнивает все возможные разбиения для всех атрибутов и выбирает наилучший атрибут и наилучшее разбиение для него. В алгоритме CART, в качестве функции оценки разбиения выборки, используется показатель Джини, который при бинарной классификации выражается как (3):

$$Gini_t^{split} = \frac{N_1}{N} Gini_{t_1} + \frac{N_2}{N} Gini_{t_2} \rightarrow \min, \quad (3)$$

где  $N$  – число объектов в текущей вершине  $t$  дерева (вершине-предке);  $N_1, N_2$  – число объектов в вершинах  $t_1$  и  $t_2$ , соответствующих левому и правому вершинам-потомкам в случае построения бинарного дерева [9].

На сегодняшний день решающие деревья нечасто используются на практике как отдельные методы классификации. В то же время, как оказалось, они очень хорошо объединяются в композиции – решающие леса, например, Random Forest, Adaboost и Xgboost, которые являются одними из наиболее сильных и перспективных моделей, позволяющих понизить уровень переобучения. Применительно к решению задачи классификации процесс ансамблирования основывается на компенсации ошибок базовых классификаторов за счет различных способов комбинирования и объединения их классификационных решений.

Для оптимизации работы алгоритмов CART, Random Forest, Adaboost и Xgboost, повышения точности их моделей и борьбы с переобучением проводилась настройка гиперпараметров деревьев с помощью алгоритмов Random Search и Grid Search библиотеки scikit-learn пакета Python. В результате были получены высокие оценки классификации для всех рассмотренных моделей. При этом для модели Random Forest была достигнута максимальная точность классификации неблагонадежных объектов, составившая 93%.

С помощью дерева CART были определены ключевые показатели деятельности кредитных организаций, а именно: «Прибыль», «Счета в Банке России», «Ценные бумаги». При использовании этих показателей, на примере модели CART, удалось существенно повысить точность классификации кредитных организаций: с 78% до 85%. В таблице 2 представлены итоговые метрики качества модели CART, построенной на 23 исходных показателях, и модели CART, реализованной на трех наиболее важных показателях, по классам, где «0» – класс благонадежных объектов, «1» – класс неблагонадежных объектов.

**Таблица 2.** Метрики качества моделей дерева CART.

Метрика	CART (23 показателя)		CART (3 показателя)	
	0	1	0	1
Precision	82%	71%	90%	79%
Recall	78%	73%	84%	86%
F1-score	80%	70%	87%	83%
Accuracy	78%		85%	
AUC	77%		82%	

Высокие значения метрик качества моделей CART – Accuracy, Precision, Recall, F1, рассчитанные отдельно для благонадежных и неблагонадежных классов объектов, свидетельствуют о целесообразности применения моделей CART для выявления высокорисковых кредитных организаций (точность классификации неблагонадежных объектов при использовании наиболее важных показателей составила 79%) [9].

В таблице 3 представлены итоговые метрики качества моделей Random Forest, Adaboost и Xgboost, по классам, где «0» – класс благонадежных объектов, «1» – класс неблагонадежных объектов.

**Таблица 3.** Метрики качества моделей лесов решений на 23 показателях.

Метрика	Random Forest		Adaboost		Xgboost	
	0	1	0	1	0	1
Precision	79%	93%	76%	92%	76%	92%
Recall	97%	64%	98%	55%	97%	56%
F1-score	87%	76%	86%	69%	85%	69%
Accuracy	83%		80%		80%	
AUC	87%		78%		81%	

Заметим, что поиск оптимальных значений гиперпараметров (или оптимизация) для рассмотренных моделей позволил существенно повысить их точность. На рисунке 2 представлена гистограмма, которая демонстрирует эффект от проведения процедуры оптимизации для модели дерева CART и моделей лесов решений Random Forest, Adaboost, Xgboost.

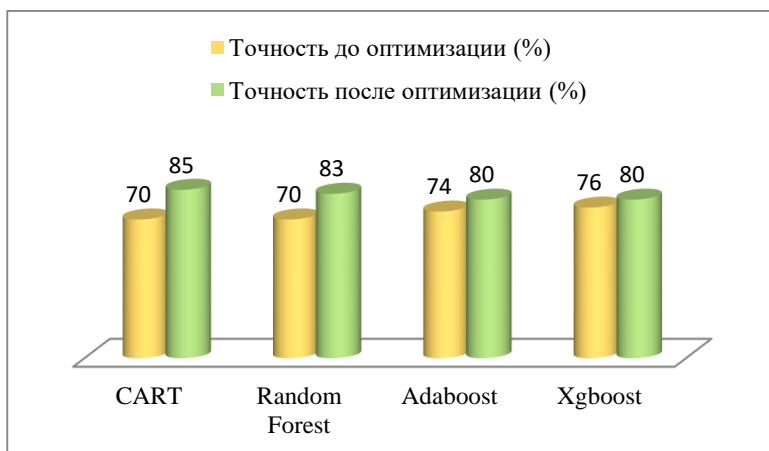


Рис. 2. Результаты оптимизации моделей CART, Random Forest, Adaboost и Xgboost.

Вычисления для деревьев и лесов решений требуют заметных временных затрат. В этой связи, расчеты для рассмотренных моделей проводились на двух вычислительных системах: на облачном сервисе Google Colab [10] и на гетерогенной платформе HybriLIT [11]. В таблице 4 приведено время вычислений для разработанных моделей CART, Random Forest, Adaboost и Xgboost с использованием указанных вычислительных сред.

Таблица 4. Время вычислений на сервере Google и HybriLIT.

Модель	Время поиска оптимальных гиперпараметров		Отношение $\frac{t_1}{t_2}$	Кол-во обработанных объектов
	Сервер Google ( $t_1$ )	Платформа HybriLIT ( $t_2$ )		
CART	28 мин. 49 сек.	8 мин. 47 сек.	3,3	576480
Random Forest	58 мин. 6 сек.	1 мин. 14 сек.	47	3252
Adaboost	2 часа 54 мин. 39 сек.	4 мин. 5 сек.	43	2196
Xgboost	65 мин. 23 сек.	1 мин. 31 сек.	43	5388

Данные таблицы 4 показывают, что для поиска оптимальных гиперпараметров с использованием платформы HybriLIT требуется существенно меньше времени, чем при использовании сервиса Google Colab. Из представленных результатов следует, что использование гибридных вычислительных архитектур позволяет существенно ускорить решение научно-прикладных задач, а гетерогенный вычислительный кластер HybriLIT является эффективным средством для достижения этой цели [12].

## 5 Прогнозирование финансового состояния кредитных организаций на основе сингулярно-спектрального анализа

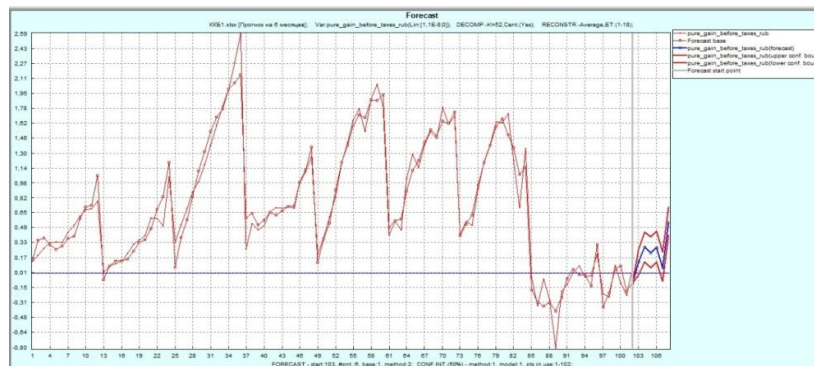
На четвертом, завершающем, этапе исследования была предложена методика комплексного и совместного применения моделей деревьев и лесов решений и сингулярно-спектрального анализа в подходе «Гусеница»-SSA к высокорисковым объектам,

идентифицированным с использованием методики статистического анализа данных, для оценки и среднесрочного прогнозирования финансового состояния кредитных организаций. Для этих целей авторы использовали программный продукт CaterpillarSSA [13].


На основе сингулярно-спектрального анализа методом «Гусеница»-SSA развит новый подход для исследования и прогнозирования временных рядов ключевых показателей деятельности кредитных организаций, а именно «Прибыль», «Счета в Банке России», «Ценные бумаги». Представлены результаты анализа для кредитных организаций двух типов: для банка с отзыванной лицензией (АО «ККБ») и для благонадежного банк (АО «Т-Банк»).

Продемонстрирована возможность декомпозиции временных рядов ключевых показателей на составляющие: трендовые, гармонические и случайный шум. Показано, что для благонадежных организаций тренд ключевых показателей имеет тенденцию к росту, в то время как для неблагонадежных – тренд «спадает» к моменту отзыва лицензии. Анализ гармонических составляющих ключевых показателей деятельности кредитных организаций является перспективной задачей Росфинмониторинга, так как позволяет выявлять потенциальные нарушения со стороны кредитных организаций. Так, периодические финансовые операции, отличные от закономерной банковской деятельности, могут являться индикатором преступной деятельности банка.

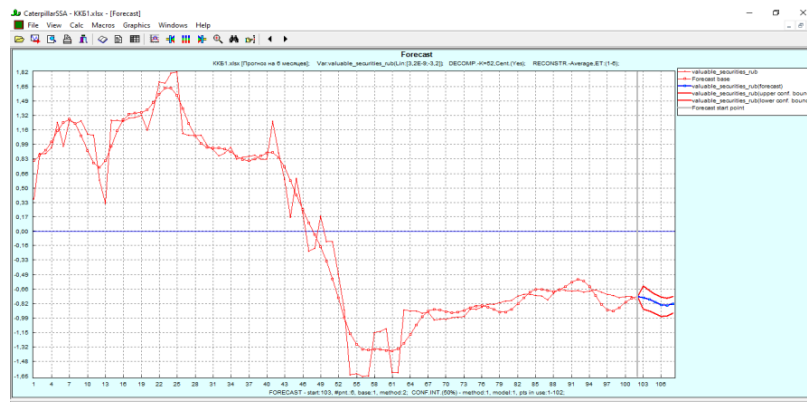
На основе отобранных трендовых и гармонических компонент была выполнена реконструкция временных рядов ключевых показателей и реализовано надежное прогнозирование динамики финансового состояния кредитных организаций на 6 месяцев вперед. Для примера, на рисунках 3, 4, 5 приведены результаты прогнозирования значений показателей «Прибыль», «Счета в Банке России» и «Ценные бумаги» для АО «ККБ» соответственно на период в 6 месяцев вперед, начиная с 103 точки отчета: на рисунке этот месяц отмечен вертикальным отрезком серого цвета. Слева от указанного отрезка изображен участок исходного ряда и его аппроксимация на основе 18-ти компонент. Справа от указанного отрезка: а) линией синего цвета представлена прогнозная кривая; в) красными жирными линиями показаны кривые, отвечающие доверительному интервалу. Уровень доверия был задан равным 0.5 [14].



**Рис. 3.** Фактические и прогнозируемые значения показателя «Прибыль» для АО «ККБ» на период в 6 месяцев.



**Рис. 4.** Фактические и прогнозируемые значения показателя «Счета в Банке России» АО «ККБ» на период в 6 месяцев.



**Рис. 5.** Фактические и прогнозируемые значения показателя «Ценные бумаги» для АО «ККБ» на период в 6 месяцев.

Для оценки точности прогнозирования рассчитаем среднюю абсолютную процентную ошибку MAPE [15] по формуле (4).

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|x_t - \hat{x}_t|}{|x_t|} \times 100\% \quad (4)$$

где  $x_t$  – фактическое значение временного ряда показателя в момент  $t$ ;  
 $\hat{x}_t$  – прогнозное значение временного ряда показателя в момент  $t$ .  
 $n$  – длина временного ряда.

В таблице 5 представлены точность и ошибки прогнозных моделей для показателей деятельности АО «ККБ»: «Прибыль», «Счета в Банке России», «Ценные бумаги». Видно, что точность прогноза для всех рассмотренных показателей, превышает 80%, что, в свою очередь, свидетельствует о целесообразности применения сингулярно-спектрального анализа в подходе «Гусеница»-SSA для оценки и прогноза финансового состояния кредитных организаций.

**Таблица 5.** Результаты прогнозирования с использованием «Гусеница»-SSA.

<i>Прогнозируемый показатель</i>	<i>Точность прогноза</i>	<i>Ошибка прогноза (MAPE)</i>
Прибыль	82%	18%
Счета в Банке России	86%	14%
Ценные бумаги	88%	12%

## 6 Заключение

В настоящем исследовании развиты новые математические модели, методы, алгоритмы и комплексы программ, предназначенные для анализа и прогнозирования финансового состояния кредитных организаций.

По результатам исследования представлены:

- 1) математические модели для оценки финансового состояния кредитных организаций на основе механизма искусственных нейронных сетей. Показано, что искусственные нейронные сети могут успешно применяться для идентификации подозрительных, с точки зрения экономической безопасности, кредитных организаций. Однако, число организаций, признанных подозрительными, оказалось довольно велико и составило 34% от общего числа анализируемых объектов. В связи с чем автором была поставлена другая задача – отобрать высокорисковые кредитные организации, анализ которых необходимо провести в первую очередь.

- 2) комплексная методика идентификации высокорисковых кредитных организаций. С использованием методов статистического анализа данных и соответствующих вычислительных алгоритмов удалось разработать новый подход, позволяющий осуществить прогнозирование попадания кредитных организаций в зону повышенного риска (порядка  $5 \div 7$  % организаций от общего количества объектов) для проведения их углубленного финансового расследования. Всего спрогнозировано  $47 \div 60$  % фактов отзыва лицензий у благонадежных кредитных организаций.
- 3) математические методы и вычислительные алгоритмы для классификации кредитных организаций с использованием моделей дерева решений CART и лесов решений Random Forest, Adaboost и Xgboost. Продемонстрирована эффективность применения указанных методов для реализации задачи классификации кредитных организаций. С помощью деревьев и лесов решений удалось определить ключевые показатели деятельности кредитных организаций, а именно «Прибыль», «Счета в Банке России», «Ценные бумаги». При использовании этих показателей для формирования модели CART удалось существенно повысить точность классификации кредитных организаций с 78% до 85%. Расчеты для моделей CART, Random Forest, Adaboost и Xgboost проводились на двух вычислительных системах: на облачном сервисе Google Colab и на гетерогенной платформе HуbriLIT. Показано, что скорость вычислений на платформе HуbriLIT существенно превосходит скорость вычислений на Google Colab.
- 4) методика комплексного и совместного применения моделей деревьев и лесов решений и сингулярно-спектрального анализа в подходе «Гусеница»-SSA к высокорисковым объектам, идентифицированным с использованием методики статистического анализа данных. Разработанная методика предназначена для исследования и прогнозирования временных рядов ключевых показателей деятельности кредитных организаций: «Прибыль», «Счета в Банке России», «Ценные бумаги». Наглядно продемонстрирована возможность декомпозиции анализируемых временных рядов ключевых показателей на их составляющие: трендовые, гармонические и случайный шум. Показано, что тренд временных рядов ключевых показателей благонадежного банка имеет тенденцию к росту, в то время как для неблагонадежного банка тренд ключевых показателей «спадает» к моменту отзыва лицензии. На основе трендовых и гармонических составляющих ряда выполнена реконструкция и последующее прогнозирование рассмотренных временных рядов на 6 месяцев вперед. Анализ гармонических составляющих является перспективной задачей Росфинмониторинга, так как позволяет выявлять потенциальные нарушения со стороны кредитных организаций. Периодические финансовые операции, отличные от закономерной банковской деятельности, могут являться индикатором преступной активности кредитной организации.

## Литература

- [1] Российская Федерация. Законы. О противодействии легализации (отмыванию) доходов, полученных преступным путем, и финансированию терроризма: федеральный закон [принят Государственной Думой 13 июля 2001 года: по состоянию на 06 июля 2016 года]. – Справочно-правовая система «Консультант Плюс». – Текст : электронный. – URL: [http://www.consultant.ru/document/cons\\_doc\\_LAW\\_32834/](http://www.consultant.ru/document/cons_doc_LAW_32834/) (дата обращения: 07.07.2024).
- [2] Центральный банк Российской Федерации : официальный сайт. – URL: [https://www.cbr.ru/banking\\_sector/credit/](https://www.cbr.ru/banking_sector/credit/) (дата обращения: 04.03.2024). – Текст : электронный.
- [3] Применение нейронных сетей и метода главных компонент для идентификации кредитных организаций, потенциально вовлеченных в процесс по легализации преступных доходов. Иванов В.В., Акишина Е.П., Приказчикова А.С. Известия Исык-Кульского форума бухгалтеров и аудиторов стран Центральной Азии. 2022. № 2 (37). С. 294-296.
- [4] StatSoft, Inc. (2011). STATISTICA (data analysis software system), version 10. [www.statsoft.com](http://www.statsoft.com).
- [5] Python: [Электронный ресурс]. URL: <https://www.python.org>. (Дата обращения: 19.03.2024).
- [6] Разработка математических моделей для анализа состояния кредитных организаций на основе искусственных нейронных сетей Приказчикова А.С., Иванов В.В., Акишина Е.П. Модели, системы, сети в экономике, технике, природе и обществе. 2024. № 4. с. 115-122.

- [7] Айвазян, С.Л. Прикладная статистика. Исследование зависимостей / С.А. Айвазян, И.С. Енюков, Л.Д. Мешалкин. – Москва : Издательство «Финансы и статистика», 1985. – 488 с. – ISBN отсутствует.
- [8] Акишина Е.П., Иванов В.В., Крянев А.В., Приказчикова А.С. Многомерный анализ данных в задаче прогнозирования попадания кредитных организаций в зону риска. Вестник НИЯУ МИФИ. 2024;13(1):22-29. <https://doi.org/10.26583/vestnik.2024.302>. EDN: HUDHFW.
- [9] Акишина Е.П., Иванов В.В., Крянев А.В., Приказчикова А.С. Разработка математических моделей классификации кредитных организаций с использованием деревьев решений и их ансамблей. Вестник НИЯУ МИФИ. 2024;13(4):242-250. <https://doi.org/10.26583/vestnik.2024.350>. EDN: LGWWEN.
- [10] Google Colaboratory: [Электронный ресурс]. URL: <https://colab.google>. (Дата обращения: 21.05.2024).
- [11] Гетерогенная платформа «HybriLIT»: [Электронный ресурс]. URL: <http://hlit.jinr.ru>. (Дата обращения: 28.07.2024).
- [12] Decision Trees and Forests in Classification of Credit Institutions A.S. Prikazchikova, V.V. Ivanov, E.P. Akishina. Physics of Particles and Nuclei Letters, 2025, Vol. 22, No. 1, pp. 69-76.
- [13] GistaT Group. CaterpillarSSA, version 3.40. Professional M Edition. <http://www.gistatgroup.com/cat/>.
- [14] Иванов В.В., Крянев А.В., Приказчикова А.С., Акишина Е.П. Прогнозирование финансового состояния кредитных организаций на основе сингулярно-спектрального анализа. Вестник НИЯУ МИФИ. 2025;14(1):50-63. <https://doi.org/10.26583/vestnik.2025.1.5>. EDN: RKSSFZ.
- [15] Турунцева М.Ю. Оценка качества прогнозов: простейшие методы // Российское предпринимательство, 2011. Т. 12, № 8 (1). С. 50-56.