

Применение математического моделирования для прогнозирования спреда корпоративных облигаций

А.А. Галимнуров, А.С. Исмаилова

Уфимский университет наук и технологий

Аннотация: В данной работе проведен анализ классических методов машинного обучения, применяемых для прогнозирования спредов доходности корпоративных облигаций. Исследуются как линейные методы, такие, как метод главных компонент, частичных наименьших квадратов, так и нелинейные методы копульной регрессии, адаптивных регрессионных сплайнов, также в работе исследуется возможность применения модели случайного леса и классической нейронной сети. В работе приведено описание данных для прогнозирования, а также представлены некоторые результаты эмпирического анализа. Полученные результаты могут существенно повлиять на практиков и научное сообщество, стремящихся к повышению точности прогнозирования и оптимизации инвестиционных стратегий.

Ключевые слова: машинное обучение, финансовый инжиниринг, моделирование фондового рынка, рынок облигаций.

Введение

Прогнозирование финансовых рынков – это сложная задача, поскольку финансовые временные ряды обладают нестационарными характеристиками. Точное предсказание доходности финансовых активов и изменений на рынке имеет важное значение, как для целей инвестирования, так и для хеджирования портфелей, помогая инвесторам сократить риск финансовых потерь. В связи с этим, как инвесторы, так и разработчики торговых стратегий стремятся к количественной оценке рисков и более точному прогнозированию будущей доходности. В последние годы методы машинного обучения вызвали значительное внимание в контексте моделирования финансовых временных рядов, благодаря их способности существенно снижать ошибки прогнозирования ([1], [2]). Помимо моделей, основанных на машинном обучении, для прогнозирования можно использовать и другие модели. В работе [3] описываются техники моделирования, основывающиеся на линейных предположениях. В исследованиях ([4], [5]) рассматриваются нелинейные регрессионные

техники, однако они требуют предварительной спецификации модели перед оценкой параметров. Хотя модели машинного обучения все еще требуют предположений о распределениях входных данных, они более гибкие по сравнению с традиционными статистическими техниками. Подходящая модель может быть изменена с использованием обучающих наборов данных, что делает метод машинного обучения оптимальным.

Цель данного исследования – применить различные методы машинного обучения для прогнозирования спредов доходности корпоративных облигаций. В частности, в данном исследовании используются гребневая регрессия, мультивариантные адаптивные регрессионные сплайны, нейронные сети, случайные леса и регрессия методом опорных векторов. Мы сравниваем предсказательную силу этих моделей с конкурирующими моделями прогнозирования, такими, как метод наименьших квадратов, регрессия на основе главных компонент, метод частичных наименьших квадратов и регрессия на основе гауссовой копулы.

Обзор литературы по применению методов машинного обучения в прогнозировании финансовых рынков демонстрирует, что эти методы: такие, как искусственные нейронные сети, метод опорных векторов, случайные леса и гибридные модели, значительно превосходят традиционные линейные подходы в некоторых задачах. Так, исследования ([6], [7]) предоставляют полноценный обзор, влиятельных статей, связанных с машинным обучением на финансовых рынках за последние два десятилетия. Этот обзор явно демонстрирует, что модели машинного обучения (например, метод опорных векторов и случайный лес) более точны в прогнозировании цен на акции и оптимизации портфелей по сравнению с традиционными моделями. В статье [7] разобран случай, когда метод опорных векторов прогнозирует будущую цену акций, лучше стандартных моделей. В статье [8] также описывается эмпирический анализ различных моделей машинного обучения, который

подтверждает, что случайный лес является более точным в прогнозировании доходностей акций для построения портфелей, чем дерево решений или метод опорных векторов. Другой важной задачей для математического моделирования является оценка кредитного рейтинга эмитента. Под такой оценкой всегда лежит модель скоринга. Так, авторы в статьях ([9], [10]) отмечают, что методы машинного обучения, такие как случайные лес и многослойные перцептроны улучшают точность прогнозирования корпоративных кредитных рейтингов и риска дефолта, особенно при недостатке данных. Подзадачей для оценки кредитного рейтинга является прогнозирование корпоративного банкротства. Так, работы ([11], [12]) показывают, что случайные леса превосходят логистическую регрессию и дискриминантный анализ при прогнозировании банкротств и кредитных рисков, как минимум на 10%.

Искусственные нейронные сети широко используются для прогнозирования фондовых рынков, доходностей облигаций и корпоративных кредитных спредов. Исследования ([13], [14]) подтверждают, что нейронные сети превосходят традиционные модели в точности прогнозирования. Кроме того, [15] показывает, что модель на основе нейронной сети демонстрирует хорошие результаты по точности прогнозирования банкротства в секторе розничной торговли во Франции. Метод достигает точности прогнозирования в 94,03%, тогда как логистическая регрессия и дискриминантный анализ показывают результаты в 90,00% и 84,39%, соответственно. Дополнительные эмпирические доказательства эффективности прогнозирования можно найти в работе [16], которая показывает, что подход на основе нейронной сети может предсказывать будущие цены акций, и в работе [17], где отмечена значительная точность прогнозирования краткосрочных валютных курсов.

Прогностические модели

Сначала рассмотрим три линейные регрессионные модели: на основе метода наименьших квадратов, метода главных компонент, метода частичных наименьших квадратов. Метод наименьших квадратов (ordinary least squares - OLS) — это стандартный метод регрессионного анализа, используемый для оценки параметров линейной регрессии. Цель OLS — минимизировать сумму квадратов отклонений наблюдаемых значений зависимой переменной от предсказанных значений модели.

Регрессия на основе главных компонент представляет собой стандартную линейную регрессионную модель, основанную на методе главных компонент (principal component analysis - PCA), который используется для оценки коэффициентов модели. PCA – это инструмент для уменьшения размерности данных, который проецирует данные с высокой размерностью на пространства меньшей размерности, называемые главными компонентами, сохраняя при этом основную часть информации (дисперсию) исходного набора данных. Этот метод особенно полезен для наборов данных с высоко коррелированными переменными. Первая главная компонента (1-я PC) – это направление наибольшей дисперсии в данных, а k -я PC – это ортогональное направление, имеющее наибольшую дисперсию по сравнению с предыдущими $k-1$ компонентами. Таким образом, первая PC объясняет наибольшую возможную дисперсию, вторая PC сохраняет вторую по величине дисперсию, и так далее. Следует также отметить, что собственное значение используется для измерения количества дисперсии, сохраненной каждой PC. Для получения дополнительной информации см. [18]. Итак, такая регрессия полезна для преодоления проблемы мультиколлинеарности с помощью использования подмножества главных компонент с высокой дисперсией для регрессии. В стандартной линейной регрессионной модели

$$Y = X\beta + \varepsilon, \tag{1}$$

коэффициенты регрессии можно оценить с помощью формулы $\hat{\beta} = (X'X)^{-1}X'Y$. Для выполнения регрессии метод главных компонент (principal component regression - PCR) мы преобразуем полную матрицу независимых переменных X в её главные компоненты. Пусть $R = XU$, где U — матрица нормированных собственных векторов матрицы $X'X$, с условием что $U'U = UU' = E$. Стандартная линейная регрессионная модель может быть записана как:

$$Y = XU' \beta + \varepsilon = R\eta + \varepsilon, \quad (2)$$

где $\eta = U' \beta$, и η может быть определена как $\hat{\eta} = (R'R)^{-1}R'Y$. Наконец, оценка коэффициентов β в PCR определяется как $\tilde{\beta} = U(R'R)^{-1}R'Y$, где используется другой набор независимых переменных. Для получения дополнительной информации см. [20].

Регрессия на основе метода частичных наименьших квадратов также подходит для решения проблем мультиколлинеарности, создавая линейную регрессию на основе ортогональных проекций. Матрицу регрессии в этом случае можно представить как произведение, так называемых, матриц счетов и нагрузок - объектов, которые получаются из исходной путем снижения размерности исходной матрицы – перехода на латентные компоненты методом частичных наименьших квадратов. Для получения дополнительной информации см. [21].

В данном исследовании мы также рассматриваем несколько нелинейных регрессионных моделей, Общий вид параметрической регрессионной модели для непрерывных и дискретных откликов можно представить в виде:

$$Y_i = F_i^{-1}\{\Phi(\varepsilon_i); \lambda\}, i = 1, \dots, n, \quad (3)$$

где $F_i\{\cdot; \lambda\} = F(\cdot | x_i; \lambda)$ - функция распределения случайной величины Y_i при x_i (регрессор) и $\Phi()$ - стандартное нормальное распределение и ошибки ε_i а λ - это вектор параметров.

Гауссова линейная регрессионная модель $Y_i = x_i^T \beta + \sigma \varepsilon_i$ соответствует $F_i \{Y_i; \lambda\} = \Phi((Y_i - x_i^T \beta) / \sigma)$, $\lambda = (\beta^T, \sigma)^T$, а вектор ошибок ε распределен нормально. При этом зависимость между переменными моделируется с использованием Гауссовой копулы, так что совместная функция распределения данных определяется как:

$$\text{prob}(Y_1 \leq y_1, \dots, Y_n \leq y_n) = \Phi_n(\varepsilon_1, \dots, \varepsilon_n; P) \text{ где } \varepsilon_i = \Phi^{-1}\{F(y_i | x_i)\}, \quad (4)$$

Следующий метод - многомерная адаптивная регрессия на сплайнах (multivariate adaptive regression splines - MARS) это непараметрический метод, который эффективно моделирует нелинейность. Преимущество этой модели заключается в возможности учитывать как линейные, так и нелинейные зависимости. Это обосновано тем, что модель строится с использованием базисных функций сплайнов, где узлы и степени полиномов определяются данными. Сплайновая функция — это кусочно-полиномиальная функция, для заданных узлов определяющаяся следующим образом:

$$f(x) = \beta_0 + \beta_1 x + \dots + \beta_p x^p + \sum_{k=1}^K \beta_{p+k} (x - t_k)_+^p, \quad (5)$$

Процесс построения модели MARS включает два этапа: сначала создается переобучающая модель с избытком базисных функций, затем менее значимые функции удаляются с помощью критерия обобщенной кросс-валидации. Параметры итоговой модели оцениваются методом наименьших квадратов [22].

Метод опорных векторов (support vector machine - SVM) , разработанный [23], это алгоритм машинного обучения, в основном используемый для классификации, но также применимый для регрессии (SVM-регрессия). Чтобы построить оптимальную гиперплоскость, выполняющую задачи классификации, SVM минимизирует следующую функцию ошибок:

$$0.5r'r + C \sum_{i=1} \text{sigm}_i \rightarrow \min, \quad (6)$$

при следующих ограничениях:

$$y_i(r'\phi(x_i) + b) \geq 1 - \text{sigm}_i, \quad i = 1, 2, \dots, K, \quad y \in \{-1, +1\}, \quad (7)$$

где i - это K обучающих наборов, а b - константа. C , r и sigm - это параметр ёмкости, вектор коэффициентов и параметры для неразделимых данных соответственно. SVM расширяется для регрессионного анализа, где регрессия с поддержкой векторов строит гиперплоскости, максимизируя зазор для минимизации ошибки обобщения. SVM-регрессия принимает детерминированную функциональную форму плюс аддитивный шум: $y = g(x) + \text{шум}; g(x) = \langle r, x \rangle + b$, где r — вектор коэффициентов. Оптимальная функциональная форма g получается путем обучения SVM на обучающем наборе. В анализе мы используем радиальную базисную функцию: $H(X_i, X_j) = \exp(-\gamma |x_i - x_j|^2)$, где $H(X_i, X_j) = \phi(X_i)\phi(X_j)$. Для получения дополнительной информации см. [24].

Следующий популярный, рассмотренный в исследовании метод - метод случайного леса, введенный [25], является ансамблевым алгоритмом классификации, в котором дерево является базовым классификатором. Подобно методу опорных векторов, случайный лес не требует предположений о конкретном распределении данных и их нормализации перед моделированием. Алгоритм [25] использует бутстрэп-агрегирование для создания коллекции деревьев решений, что позволяет получить мощные предсказательные способности. Прогнозирование производится путем усреднения предсказаний отдельных деревьев.

Нейронные сети — это метод, основанный на данных и самоадаптации. Согласно теореме об универсальном приближении, нейронные сети с одним скрытым слоем могут аппроксимировать любую непрерывную многомерную функцию с произвольной точностью. Зависимость между входом и выходом

сети выражается как функция, что эквивалентно модели нелинейной регрессии. Основным элементом нейронной сети — логистическая функция. Многослойные сети прямого распространения часто используются в финансовых приложениях. В нейронной сети с тремя слоями отдельные элементы состоят из входного слоя, среднего слоя и выходного слоя. Средний слой получает входные сигналы с добавочным термином и передает сигналы в выходной слой [26]:

$$k_l = G(\sum \beta_{ij} x_i) = G(X' B_l), \quad (8)$$

где $l=1,2,\dots,q$; $i=0,1,\dots,p$, а x_i и β представляют сигнал от i -го входа и матрицу весов. Аналогичным образом, сигналы передаются из среднего слоя в выходной: $y = F(\sum \gamma_l k_l)$, где γ — это вектор весов. Отсюда:

$$y = F(\gamma_0 + \sum_{l=1}^q \gamma_l G(\sum \beta_{ij} x_i)) = g(X, \zeta), \quad (9)$$

где ζ — это вектор весов сети.

Данные

Для целей сбора и обработки данных был реализован набор программ, использующих различные API сервисы и простые парсеры для сбора различной информации за 2015 – 2021 год на фондовом рынке облигаций (TQBR). Данные забираются и обрабатываются автоматически с использованием Python, и хранятся на развернутом SQL-сервере, также часть функций по поиску и обработке данных реализована в SQL. Все собираемые данные можно разбить на 7 блоков. Первый содержит макроэкономическую статистику, включая инфляцию, ключевую ставку, динамику кредитования. Второй включает показатели динамики цен на ресурсы: нефть, газ, золото, другие редкие и драгоценные металлы, пшеницу. Третий блок охватывает технические индикаторы, включая около 27 популярных базовых показателей, полученных с помощью библиотеки pandas_ta, метрики ликвидности, трендовые и импульсные индикаторы. Четвертый блок посвящен

фундаментальным индикаторам, характеризующим финансовую деятельность компании: Кредитный рейтинг, Совокупный долг\ EBITDA, Чистая рентабельность и т.д. Пятый блок включает в себя широкий набор индексов Московской биржи: IMOEX, индекс волатильности, индексы облигаций в зависимости от рейтинга и дюрации, индексы денежного рынка. Шестой блок представляет описание кривой КБД — как разницы между значениями в выделенных точках. Последний блок содержит в себе две пары курсов валют: USD\RUB , CNY\ RUB.

Поскольку взвешенные по объему подходы считаются предпочтительными для оценки доходностей [27], мы также применяем этот метод, рассчитывая доходности на основе взвешенной по объему средней дневной цены. Если облигации не торговались в течение нескольких дней, или их среднедневной оборот меньше 1 млн рублей, то они исключались из выборки. Плюс мы ограничиваем нашу выборку облигациями со сроком погашения более одного года, для качественного сравнения доходностей.

Отдельно выделим ряд объясняющих переменных, которые были признаны важными факторами влияния на спреды доходности корпоративных облигаций в предыдущих исследованиях. Во-первых, рассмотрим кредитный рейтинг облигации, как ключевую переменную для оценки кредитного риска. Мы присваиваем каждой облигации числовой рейтинг на основе шкал агентств «Эксперт РА»/ «АКРА», где облигации наивысшего качества (ruAAA) присваивается единица, а облигациям с низким рейтингом – более высокое числовое значение. Ожидается, что более низкое кредитное качество (выраженное более высоким числовым значением рейтинга) будет связано с большими спредами доходности. Вторым важным признаком является волатильность процентных ставок, которая рассчитывается как стандартное отклонение ежедневных доходностей государственных облигаций с фиксированным сроком погашения за 12

месяцев до даты сделки с корпоративной облигацией, как это было предложено. Поскольку волатильность процентных ставок положительно коррелирует с волатильностью рынка в целом, мы ожидаем, что она увеличит спреды доходности корпоративных облигаций. Аналогично волатильность акций компаний измеряется стандартным отклонением доходностей на индексе Московской биржи (IMOEX), скорректированным на дневные доходности за 12 месяцев до даты сделки с облигацией. Ожидается, что волатильность акций также будет положительно коррелирована со спредами доходности. Краткосрочные процентные ставки представляют собой доходность государственных облигаций с постоянным сроком погашения в один месяц. В соответствии с выводами, рост краткосрочной процентной ставки снижает риск дефолта, и, соответственно, мы ожидаем отрицательную зависимость между краткосрочной процентной ставкой и спредами доходности корпоративных облигаций. Наклон кривой доходности определяется как разница между доходностью государственных облигаций на массиве сроков погашения [0.1, 0.5, 1, 1.5, 2, 3, 5, 10]. Согласно теоретическим и эмпирическим исследованиям [28], ожидается отрицательная зависимость между наклоном кривой доходности и спредами доходности. Мы также включаем срок погашения и купонные ставки как детерминанты спредов доходности. Купонная ставка измеряется в процентах и, положительно коррелирована со спредами доходности, так как процентные платежи по корпоративным облигациям облагаются налогом, а по государственным – нет. Наконец, ликвидность облигаций измеряется несколькими метриками на основе кол-ва сделок, спредов, объёмов бумаги и всего рынка. Поскольку инвесторы требуют премии за ликвидность, мы ожидаем, что спреды доходности будут отрицательно связаны с ликвидностью, аналогично подходу.

Эмпирический анализ

В данном исследовании мы сосредотачиваемся на прогнозировании спредов доходности корпоративных облигаций без возможности досрочного погашения, используя ежедневные данные. Основной подход заключается в построении прогнозов на текущую дату T на основе временного окна длиной 500 дней в интервале $[T-1, T-500]$. Такой подход позволяет учитывать недавние тенденции и динамику рынка, что важно для повышения точности прогнозов. Мы применяем различные методы машинного обучения, чтобы определить, какой из них наиболее эффективен для прогнозирования спредов доходности на российском рынке корпоративных облигаций. Для оценки качества прогнозов мы используем метрику корня из среднеквадратичной ошибки (root mean square deviation - RMSE). RMSE была выбрана, поскольку она чувствительна к крупным отклонениям между прогнозируемыми и фактическими значениями. Это особенно важно для финансовых данных, где ошибки прогнозирования, даже в небольшом числе случаев, могут привести к значительным финансовым рискам. В отличие от других метрик, таких, как средняя абсолютная ошибка, RMSE акцентирует внимание на крупных ошибках, что делает ее более подходящей для оценки моделей, применяемых в условиях высокой изменчивости данных. В ходе анализа классическая нейронная сеть и метод случайного леса показали схожие результаты на описанных данных, продемонстрировав предиктивную способность, в среднем на 23% превосходящую линейные регрессии. При этом остаётся открытым вопрос: как будут работать рекомендательные системы, построенные на основе этих моделей? Этот аспект требует дальнейших исследований. Дополнительно в рамках анализа были проверены базовые гипотезы. Установлено, что спреды доходности имеют отрицательную корреляцию с ликвидностью, демонстрируют высокую зависимость от кредитных рейтингов и состояния денежного рынка. Слабая зависимость

спредов от технических индикаторов подтвердила, что их влияние ограничено для этого типа бумаг. При этом обнаружена позитивная зависимость от волатильности фондового рынка, что согласуется с общими ожиданиями для корпоративных облигаций.

Заключение

В этом исследовании мы сравнили девять различных методов прогнозирования, включая пять инструментов машинного обучения, с целью прогнозирования спредов доходности. Мы обнаружили эмпирические доказательства того, что метод нейронных сетей явно превосходит конкурирующие модели по точности прогнозирования. Кредитные рейтинги оказались наиболее значимым фактором, влияющим на спреды доходности корпоративных облигаций. Некоторые результаты подтвердили предыдущие результаты. Так, в работе [29] авторы выяснили, что волатильность акций также является важным детерминантом спредов доходности, а также обнаружили, что волатильность процентных ставок играет ключевую роль в определении спредов доходности. С практической точки зрения, наше исследование способствует оптимизации управления портфелем, предлагая более надежные оценки спредов доходности корпоративных облигаций. Кроме того, наш анализ с использованием методов машинного обучения может обеспечить эффективное хеджирование риска дефолта корпоративных облигаций на практике. Точность прогнозирования спредов доходности с использованием машинного обучения может позволить управляющим портфелями облигаций улучшить качество своих стратегий портфеля и эффективность своих портфелей. Одним из ограничений нашего исследования является то, что мы не проводили историческую валидацию модели на заданном портфеле бумаг с целью сравнения полученной доходности с бенчмарком; мы оставляем эти тесты для будущих исследований.

Литература

1. Culkin R. & Das S. R. Machine learning in finance: The case of deep learning for option pricing. // Journal of Investment Management, 2017, 15(4), pp. 92–100.
 2. De Spiegeleer, Dilip B, Wim, Machine Learning for Quantitative Finance: Fast Derivative Pricing. // Hedging and Fitting, 2018, URL: doi.org/10.2139/ssrn.3191050.
 3. Brooks, C. Linear and non-linear (non-) forecastability of high-frequency exchange rates. // Journal of Forecasting, 1997, 16(2), pp. 125–145.
 4. A. Kanas. Non-linear forecasts of stock returns. // Journal of Forecasting, 2003, 22(4), pp. 299-315, URL: doi.org/10.1002/for.858.
 5. Lin J.-L. & Granger C. W. Forecasting from non-linear models in practice. // Journal of Forecasting, 1994, 13(1), pp. 1–9.
 6. Henrique, Sobreiro, Kimura. Machine learning techniques applied to financial market prediction. // Expert Systems with Applications, 2019, 124, pp. 226 – 251.
 7. Mishra S. & Padhy S. An efficient portfolio construction model using stock price predicted by support vector regression. // The North American Journal of Economics and Finance, 2019, 50, URL: doi.org/10.1016/j.najef.2019.101027.
 8. Ma Y., Han R., & Wang W. Portfolio optimization with return prediction using deep learning and machine learning. // Expert Systems with Applications, 2021, 165, Article 113973, URL: doi.org/10.1016/j.eswa.2020.113973.
 9. Moscatelli M., Parlapiano F., Narizzano S., & Viggiano, G. Corporate default forecasting with machine learning. // Expert Systems with Applications, 2020, 161, Article 113567, URL: doi.org/10.1016/j.eswa.2020.113567.
 10. Golbayani P., Florescu, I. & Chatterjee R. A comparative study of forecasting corporate credit ratings using neural networks, support vector
-

machines, and decision trees. // The North American Journal of Economics and Finance, 2020 54, Article 101251, URL: doi.org/ 10.1016/j.najef.2020.10125.

11. Min J. H. & Lee Y.-C. Bankruptcy prediction using support vector machine with optimal choice of kernel function parameters. // Expert Systems with Applications, 2005, 28(4), pp. 603-614.

12. Barboza F., Kimura H. & Altman E. Machine learning models and bankruptcy prediction. // Expert Systems with Applications, 2017, 83, pp. 405–417.

13. Chen A.-S., Leung M. T. & Daouk H. Application of neural networks to an emerging financial market: Forecasting and trading the Taiwan stock index. // Computers & Operations Research, 2003, 30(6), pp. 901–923.

14. Le H. H., & Viviani J.-L. Predicting bank failure: An improvement by implementing a machine-learning approach to classical financial ratios. // Research in International Business and Finance, 2018, 44, pp. 16–25.

15. Du Jardin, P. Predicting bankruptcy using neural networks and other classification methods: The influence of variable selection techniques on model accuracy. // Neurocomputing, 2010, 73(10–12), pp. 2047–2060.

16. Sureshkumar K. & Elango N. Performance analysis of stock price prediction using artificial neural network. // Global Journal of Computer Science and Technology, 2012, 12(1), pp. 18–25.

17. S. Galeshchuk. Neural networks performance in exchange rate prediction. // Neurocomputing, 2015, URL: doi.org/10.1016/j.neucom.2015.03.100.

18. Kneip A. & Utikal K. J. Inference for density families using functional principal component analysis. // Journal of the American Statistical Association, 2001, 96(454), pp. 519–542.

19. Kim J.-M., Kim D. H. & Jung H. Modeling non-normal corporate bond yield spreads by copula. // North American Journal of Economics and Finance, 2020, 53, pp. 1–15.

20. Boneh S. & Mendieta G. R. Regression Modeling Using Principal Components. // In 4th Annual Conference on Applied Statistics in Agriculture Manhattan, KS, USA, 1992, URL: doi.org/10.4148/2475-7772.1408.
21. Олейник А. Л. Применение метода частичных наименьших квадратов для обработки и моделирования аудиовизуальной речи // Научно-технический вестник информационных технологий, механики и оптики, 2015, 5, с. 886–892.
22. Friedman J. H. Multivariate adaptive regression splines. // The Annals of Statistics, 1991, pp. 1–67.
23. Vapnik V. Statistical Learning Theory, J. Wiley, 1998, 768 p.
24. Hsu C.-W. & Lin C.-J. A simple decomposition method for support vector machines. // Machine Learning, 2002, 46(1–3), pp. 291–314.
25. Breiman L. Random forests. // Machine Learning, 2001, 45(1), pp. 5–32.
26. Hornik K., Stinchcombe M. & White H. Multilayer feedforward networks are universal approximators. // Neural Networks, 1989, 2(5), pp. 359–366.
27. Bessembinder H., Kahle K. M., Maxwell W. F., & Xu D. (2009). Measuring abnormal bond performance. // Review of Financial Studies, 2009, 22.
28. Breeden, D. A Stocks, Bonds and Consumers Leading Index (SBCLI): Consumer Behavior as a Leading Indicator. // In World Finance Conference Rhodes, 2011, URL: doi.org/10.2139/ssrn.2480618.
29. Campbell J. Y. & Taksler G. B. Equity volatility and corporate bond yields. // The Journal of Finance, 2003, 58(6), pp. 2321–2350.

References

1. Culkin R. & Das S. R. Journal of Investment Management, 2017, 15(4), pp. 92–100.
-

2. De Spiegeleer, Dilip B, Wim, Hedging and Fitting, 2018, URL: doi.org/10.2139/ssrn.3191050.
 3. Brooks, C. Journal of Forecasting, 1997, 16(2), pp. 125–145.
 4. A. Kanas. Journal of Forecasting, 2003, 22(4), pp. 299-315, URL: doi.org/10.1002/for.858.
 5. Lin J.-L. & Granger C. W. Journal of Forecasting, 1994, 13(1), pp. 1–9.
 6. Henrique, Sobreiro, Kimura. Expert Systems with Applications, 2019, 124, pp. 226 – 251.
 7. Mishra S. & Padhy S. The North American Journal of Economics and Finance, 2019, 50, URL: doi.org/10.1016/j.najef.2019.101027.
 8. Ma Y., Han R., & Wang W. Expert Systems with Applications, 2021, 165, Article 113973, URL: doi.org/10.1016/j.eswa.2020.113973.
 9. Moscatelli M., Parlapiano F., Narizzano S., & Viggiano, G. Expert Systems with Applications, 2020, 161, Article 113567, URL: doi.org/10.1016/j.eswa.2020.113567.
 10. Golbayani P., Florescu, I. & Chatterjee R. The North American Journal of Economics and Finance, 2020 54, Article 101251, URL: doi.org/10.1016/j.najef.2020.101251.
 11. Min J. H. & Lee Y.-C. Expert Systems with Applications, 2005, 28(4), pp. 603-614.
 12. Barboza F., Kimura H. & Altman E. Expert Systems with Applications, 2017, 83, pp. 405–417.
 13. Chen A.-S., Leung M. T. & Daouk H. Computers & Operations Research, 2003, 30(6), pp. 901–923.
 14. Le H. H., & Viviani J.-L. Research in International Business and Finance, 2018, 44, pp. 16–25.
 15. Du Jardin, P. Neurocomputing, 2010, 73(10–12), pp. 2047–2060.
-

16. Sureshkumar K. & Elango N. Global Journal of Computer Science and Technology, 2012, 12(1), pp. 18–25.
17. S. Galeshchuk. Neurocomputing, 2015. URL: doi.org/10.1016/j.neucom.2015.03.100.
18. Kneip A. & Utikal K. J. Journal of the American Statistical Association, 2001, 96(454), pp. 519–542.
19. Kim J.-M., Kim D. H. & Jung H. North American Journal of Economics and Finance, 2020, 53, pp. 1–15.
20. Boneh S. & Mendieta G. R. 4th Annual Conference on Applied Statistics in Agriculture Manhattan, KS, USA, 1992, URL: doi.org/10.4148/2475-7772.1408.
21. Olejnik A. L. P. Nauchno-texnicheskij vestnik informacionny`x texnologij, mexaniki i optiki, 2015, 5, pp. 886–892.
22. Friedman J. H. The Annals of Statistics, 1991, pp. 1–67.
23. Vapnik V. Statistical Learning Theory, J. Wiley, 1998, 768 p.
24. Hsu C.-W. & Lin C.-J. Machine Learning, 2002, 46(1–3), pp. 291–314.
25. Breiman L. Machine Learning, 2001, 45(1), pp. 5–32.
26. Hornik K., Stinchcombe M. & White H. Neural Networks, 1989, 2(5), pp. 359–366.
27. Bessembinder H., Kahle K. M., Maxwell W. F., & Xu D. (2009). Review of Financial Studies, 2009, 22
28. Breeden, D. A World Finance Conference Rhodes, 2011, URL: doi.org/10.2139/ssrn.2480618
29. Campbell J. Y. & Taksler G. B. The Journal of Finance, 2003, 58(6), pp. 2321–2350.

Дата поступления: 6.12.2024

Дата публикации: 26.01.2025
