

Применение машинного обучения для определения спреда доходности корпоративных облигаций

Галимнуров А.А.
аспирант

Институт информатики, математики и
робототехники
Уфимский университет науки и технологий
Уфа, Россия
e-mail: artur.galimnurov@gmail.com

Исмагилова А.С.
профессор, д.ф.-м.н.

Институт информатики, математики и
робототехники
Уфимский университет науки и технологий
Уфа, Россия
e-mail: ismagilovaas@yandex.ru

Аннотация¹

В данной работе проведен анализ методов машинного обучения, применяемых для прогнозирования спредов доходности корпоративных облигаций. Исследуются как линейные, так и нелинейные модели, включая обычные наименьшие квадраты (OLS), главные компоненты регрессии (PCR), частичную (PLS), обобщенные комбинированные модели регрессии (GCMR), метод гребневой регрессии (Ridge), многочлены адаптивных регрессионных сплайнов (MARS), машины опорных векторов (SVM), случайные леса (Random Forest) и нейронные сети. В работе приведены сравнение предсказательной силы указанных моделей и оценка их эффективности в контексте прогнозирования финансовых рынков. 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

1. 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 приобрели

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. Однако такие техники моделирования, например как в [3] основываются на линейных предположениях. Кроме того, нелинейные регрессионные техники, рассматриваемые в литературе [4], [5], требуют предварительной спецификации модели перед оценкой параметров. Хотя модели машинного обучения все еще требуют предположений о распределении входных данных, они более гибкие по сравнению с традиционными статистическими техниками. Подходящая модель может быть изменена с использованием обучающих наборов данных, что делает методы машинного обучения более 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 (MARS), нейронные сети, случайные леса и регрессия методом опорных векторов (SVM). Мы сравниваем предсказательную силу этих моделей с конкурирующими моделями прогнозирования, такими как обыкновенные наименьшие квадраты (OLS), регрессия на основе главных компонент (PCR), частичные наименьшие квадраты (PLS) и маргинальная регрессия на основе гауссовой копулы (GCMR).

Обзор литературы по применению методов машинного обучения в прогнозировании финансовых рынков демонстрирует, что эти методы, такие как искусственные нейронные сети (ANN), метод опорных векторов (SVM), случайные леса (RF) и гибридные модели, значительно превосходят

Труды X Международной научной конференции "Информационные технологии интеллектуальной поддержки принятия решений", 12-14 ноября, Уфа-Баку-Чандигарх, 2024

Применение машинного обучения для определения спреда доходности корпоративных облигаций

традиционные линейные подходы в некоторых задачах.

1.1 Прогнозирование цен акций и портфелей

Исследования [6] и [7] предоставляют полноценный обзор, самых влиятельных статей, связанных с машинным обучением на финансовых рынках за последние два десятилетия. Этот обзор явно демонстрирует что модели машинного обучения (например, SVR и случайный лес) более точны в прогнозировании цен на акции и оптимизации портфелей по сравнению с традиционными моделями. В статье [7] разобран случай, когда SVR прогнозирует будущую цену акций, лучше стандартных моделей. В статье [8] также есть 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 SVM.

1.2 Оценка кредитных рейтингов и финансового риска

Под оценкой кредитного рейтинга всегда лежит модель скоринга, так авторы в статьях [9], [10] отмечают, что методы машинного обучения (SVM, RF и многослойные перцептроны) улучшают точность прогнозирования корпоративных кредитных рейтингов и риска дефолта, особенно при недостатке данных.

1.3 Прогнозирование корпоративного банкротства

Исследования [11], [12] показывают, что модели SVM и случайные леса превосходят логистическую регрессию и дискриминантный анализ при прогнозировании банкротств и кредитных рисков, как минимум на 10%.

1.4 Применение ANN

Искусственные нейронные сети (ANN) широко используются для прогнозирования фондовых рынков, доходностей облигаций и корпоративных кредитных спредов. Исследования [13], [14] подтверждают, что ANN превосходят традиционные модели в точности прогнозирования. Кроме того, [25] 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. Значительная точность прогнозирования также отмечена в прогнозировании краткосрочных валютных курсов [17]

2. Прогностические модели

Рассмотрим три линейные регрессионные модели: OLS, PCR и PLS. PCR представляет собой стандартную линейную регрессионную модель, основанную на методе главных компонент (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 (PC), 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 -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].

Мы также рассматриваем GCMR как нелинейную регрессионную модель. Метод GCMR использовался для определения факторов, влияющих на спред доходности корпоративных облигаций в исследовании [19]. Эта регрессионная модель на основе копул часто используется в литературе для моделирования ненормальных временных рядов. В частности, мы применяем этот метод для прогнозирования спреда доходности облигаций.

2.1 Регрессия на основе главных компонент (PCR)

PCR полезен для преодоления проблемы мультиколлинеарности с помощью использования подмножества главных компонент с высокой дисперсией для регрессии. В стандартной линейной регрессионной модели $Y = X\beta + \varepsilon$, коэффициенты регрессии можно оценить с помощью формулы $\hat{\beta} = (X'X)^{-1}X'Y$. Для выполнения 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 $U'U = UU' = I$. Стандартная линейная регрессионная модель может быть записана как:

$$Y = XU'U'\beta + \varepsilon = R\eta + \varepsilon,$$

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 $\hat{\beta} = U(R'R)^{-1}R'Y$, где используется другой набор независимых переменных. Для получения дополнительной информации см. [20]

2.2 Регрессия на основе частичных наименьших квадратов (PLS)

PLS создает линейную регрессионную модель, используя ортогональные проекции как предсказанных, так и наблюдаемых переменных на пространство задачи. Как и PCR, PLS подходит для данных с сильно коррелированными предикторами. Кросс-производная матрица в регрессии определяется как $K = X'Y$. Для получения оценок s и v используются векторы весов r и q следующим образом:

$$s = Xr = Gr, \quad v = Yq = Jq,$$

где G и J инициализируются, и загрузки X и Y получаются с помощью регрессии по оценкам s , например, $w = G's$ и $q = J's$. Матрицы R , S , W и Q можно получить из векторов r , s , w и q после каждой итерации. Используя оценки $S = XD$, коэффициенты регрессии можно найти с помощью:

$$\beta = D(S'S)^{-1}S'Y = DS'Y = DQ',$$

где оптимальное количество главных компонент определяется с помощью критерия кросс-валидации. Для получения дополнительной информации о PLS-регрессии см. [21]

2.3 Гауссовская копула с маргинальной регрессией (GCMR)

Мы также рассматриваем несколько нелинейных регрессионных моделей, включая пять различных методов машинного обучения. Наш анализ использует GCMR с предельным кумулятивным распределением для x_i , $G(\cdot | x_i)$. Согласно теореме Склара (см. Sklar, 1959), любая многомерная функция распределения $G_{XY}(x, y)$ может быть выражена через $G_X(x)$ и $G_Y(y)$ с помощью копулы C , определенной на $[0, 1]^n$. Совместная функция распределения в GCMR представляется как:

$$\text{Prob}(Y_1 \leq y_1, \dots, Y_n \leq y_n) = \Omega_n(\varepsilon_1, \dots, \varepsilon_n; W),$$

где $\varepsilon_i = \Omega^{-1}G(y_i | x_i)$. В частности, гауссовская копула определяется как:

$$Y_i = h(x_i, \varepsilon_i),$$

где ε_i имеет нормальное распределение с корреляционной матрицей гауссовской копулы. Для получения дополнительной информации см. [22], [19]

2.4 Ridge регрессия

Мы рассматриваем метод регуляризованной линейной регрессии, Ridge, в котором нормальное распределение не требуется. Аналогично ОМНК, оценка γ получается путем решения задачи оптимизации:

$$\text{argmin}_{\gamma \in \mathbb{R}^n} (Y - X\gamma)'(Y - X\gamma), \text{ при условии } \sum_{j=1}^q \gamma_j^2 \leq t.$$

Тогда, регуляризованная сумма квадратов остатков (Т) задается как:

$$T(\gamma) = (Y - X\gamma)'(Y - X\gamma) + \psi \|\gamma\|_2^2,$$

где ψ — параметр сжатия. Наконец, решение задачи оптимизации может быть получено путем взятия производной:

$$\frac{\partial T(\gamma)}{\partial \gamma} = -2X'(Y - X\gamma) + 2\psi\gamma, \\ \hat{\gamma} = (X'X + \psi I_q)^{-1}X'Y.$$

Дополнительные обсуждения и применения Ridge регрессии можно найти у [23]

2.5 Многомерные адаптивные регрессионные сплайны (MARS)

MARS, предложенные [24] — это непараметрический статистический метод, моделирующий множественные нелинейности в данных. Основное преимущество MARS заключается в гибкости, так как метод может обрабатывать как линейные, так и нелинейные зависимости. Модель может быть построена с использованием базисных функций сплайнов, где данные определяют степень полиномов и местоположение узлов. Сплайновая функция — это кусочно-полиномиальная функция, которая гладко соединяется в узлах. Для данного набора узлов сплайновая функция может быть записана как:

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

где p — степень полинома, t_1, \dots, t_K — узлы, а $(x)_+ = x$, если $x > 0$, и 0 в противном случае. Рассмотрим случайную выборку $(X_1, Y_1), \dots, (X_n, Y_n)$. Тогда MARS принимает форму:

$$f(X) = f(X|\beta) = \sum_{j=1}^J \beta_j B_j(X).$$

Оптимальная модель MARS выбирается в два этапа: сначала строится множество базисных функций, переобучающих данные, затем худшие базисные функции удаляются с использованием критерия обобщенной кросс-валидации. Для выбранного набора базисных функций MARS оценивает неизвестные параметры методом наименьших квадратов.

2.6 Метод опорных векторов (SVM)

Разработанная [25] и его коллегами, SVM — 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:

$$\frac{1}{2} r' r + C \sum_{i=1}^K \zeta_i,$$

при следующих ограничениях:

$$y_i(r' \phi(x_i) + b) \geq 1 - \zeta_i, \quad i = 1, 2, \dots, K, \quad y \in -1, +1,$$

где i — это K обучающих наборов, а b — константа. C , r и ζ — это параметр ёмкости, вектор коэффициентов и параметры для неразделимых данных соответственно. Параметр C контролирует штраф за ошибку. SVM расширяется для регрессионного анализа, где регрессия с поддержкой векторов строит

гиперплоскости, максимизируя зазор для минимизации ошибки обобщения. Процесс оптимизации для регрессии основан на методе декомпозиции, предложенном [26]. SVM-регрессия принимает детерминированную функциональную форму и аддитивный шум:

$$y = g(x) + \text{шум}, \quad g(x) = \langle r, x \rangle + b,$$

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 $H(X_i, X_j) = \phi(X_i) \cdot \phi(X_j)$. В зависимости от выбора параметров γ и C SVM может обеспечить разный уровень точности.

2.7 Случайный лес (Random forest)

Метод случайного леса, введенный [27] является ансамблевым алгоритмом классификации, в котором дерево является базовым классификатором. Подобно SVM, случайный лес не требует предположений о конкретном распределении данных. Случайный лес состоит из множества отдельных деревьев решений. Одно дерево строится на основе большого количества обучающих данных и случайного вектора θ_l , и классификатор состоит из входного вектора и θ_l . Алгоритм [27] использует бутстреп-агрегирование для создания коллекции деревьев решений, что позволяет получить мощные предсказательные способности. Прогнозирование производится путем усреднения предсказаний отдельных деревьев.

2.8 Нейронные сети

Нейронная сеть – 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 [28]. Функциональная зависимость между X_i и y выражается как $y = f(x_1, x_2, \dots, x_p)$, что эквивалентно стандартной модели нелинейной регрессии. Основной элемент 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:

$$k_l = G(\sum \beta_{il} x_i) = G(X^i \beta^l), \quad l = 1, 2, \dots, q, \quad i = 0, 1, 2, \dots, p,$$

где x_i и β представляют сигнал от i -го входа и матрицу весов. Аналогичным образом сигналы передаются из среднего слоя в выходной:

$$y = F(\sum \gamma_l k_l), \quad l = 1, 2, \dots, q,$$

где γ – это вектор весов. Используя эти уравнения, мы получаем:

$$y = F\left(\gamma_0 + \sum_{l=1}^q \gamma_l G(\sum \beta_{il} x_i)\right) = g(X, \xi),$$

где ξ – это вектор весов сети.

3. 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): итоги торгов на различных интервалах (часовые, дневные, недельные); качественные данные по бумагам (такие как числовые и качественные описания эмитентов, характеристики выпуска, указанные в введении); история изменения кредитных рейтингов; макропараметры по рынку – котировки основных индексов акций, валют, ресурсов; данные по денежному потоку для всех бумаг; данные по офертам на рынке и основные функции по обработке этих данных, финансовые показатели эмитентов. Все данные обрабатываются в программах, написанных на языке Python, и хранятся в созданном SQL сервере. Часть функций по поиску и обработке данных реализована в SQL. Поскольку взвешенные по объему подходы считаются предпочтительными для оценки доходностей [30], мы также применяем этот метод, рассчитывая доходности на основе взвешенной по объему средней цены сделок на последний торговый день месяца. Если облигации не торговались в последние пять торговых дней месяца, они исключаются из выборки для поддержания точности и сопоставимости данных, как рекомендовали [29].

Мы ограничиваем нашу выборку облигациями со сроком погашения более одного года. Мы рассматриваем ряд объясняющих переменных, которые были признаны важными факторами влияния на спреда доходности корпоративных облигаций в предыдущих исследованиях.

Во-первых, мы включаем 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.

Волатильность процентных ставок 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 [29]. Поскольку волатильность процентных ставок положительно коррелирует с волатильностью активов компании, мы ожидаем, что она увеличит спреда доходности корпоративных облигаций. Аналогично волатильность акций компаний измеряется стандартным отклонением доходностей на индексе

Московской биржи (ИМОЕХ), 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 со сроком погашения в 10 лет и 1 год. Согласно теоретическим и эмпирическим исследованиям [31], 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 [29].

4. Эмпирический анализ

Для прогнозирования спредов доходности корпоративных облигаций без возможности досрочного погашения мы используем различные методы прогнозирования, описанные в предыдущем разделе. Мы рассматриваем два разных горизонта прогнозирования, чтобы убедиться, что наши результаты согласуются с различными горизонтами. В частности, наш эмпирический анализ учитывает прогноз вне выборки на следующие два года для месячных спредов доходности корпоративных облигаций. Например, пусть Y_t обозначает наблюдения за год t и F_t обозначает прогнозы Y_t . Мы вычисляем прогнозы вне выборки $F_{\{2019 + j\}}$ для $j = 1$ и $j = 2$ основываясь на данных за периоды $t = 2015, \dots, 2019$. То есть, месячные спреды доходности корпоративных облигаций на 2020 год (на один год вперед) и на 2021 год (на два года вперед) прогнозируются на основе наших данных выборки. Наша цель — применить различные методы машинного обучения для прогнозирования спредов доходности корпоративных облигаций и предложить метод, который обеспечит практикам наилучшую производительность прогнозирования именно на российском рынке. Каждая модель оценивается в двух случаях: 1) горизонт прогнозирования вне выборки охватывает период с 2020 по 2021 год с использованием данных выборки (2015 по 2019),

который мы называем Случай 1 в данной статье; 2) набор данных выборки за 2015–2020 годы используется для прогнозирования спредов доходности корпоративных облигаций в 2021 году (Случай 2). Как следует из полученных результатов: GCMR является моделью с лучшей подгонкой, поскольку ее результаты оценки более согласуются с литературой корпоративных финансов. Например, как указывает, должно быть положительное отношение между купонными ставками и спредами доходности из-за налогового недостатка процентных платежей по корпоративным облигациям. Все остальные оценки коэффициентов согласуются с нашими предыдущими ожиданиями.

5. 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. В качестве предварительного анализа мы наблюдаем положительную связь между волатильностью акций фирмы и спредами доходности через визуализацию наших данных. Затем мы исследуем детерминанты спредов доходности, предоставленные нейронной сетью. Кредитные рейтинги оказались наиболее значимым фактором, влияющим на спреды доходности корпоративных облигаций. Некоторые результаты подтвердили предыдущие результаты. Так, в работе [32] авторы выяснили, что волатильность акций также является важным детерминантом спредов доходности, в [29] также обнаружили, что волатильность акций и волатильность процентных ставок играют ключевую роль в определении спредов доходности. Однако, полагаясь на более статистически сложный анализ, наше исследование предполагает, что волатильность акций имеет наибольшее влияние на спреды доходности. В частности, вес волатильности акций фирмы во входном векторе составляет 23.65, в то время как вес второго по значимости детерминанта составляет всего 0.58 по модулю. С практической точки зрения, наше исследование способствует оптимальному управлению 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. В этом исследовании мы применяем методы машинного обучения для прогнозирования спредов доходности корпоративных облигаций. Точность прогнозирования спредов доходности с использованием машинного обучения может позволить управляющим портфелями облигаций улучшить качество своих стратегий портфеля и эффективность своих портфелей. Наши результаты показывают, что волатильность акций играет наиболее

критическую роль в определении спредов доходности. Менеджеры корпоративных облигаций могут использовать наибольшее влияние волатильности акций для разработки своих стратегий хеджирования и улучшения их эффективности. Одним из ограничений нашего исследования является то, что мы не тестировали эмпирически последствия хеджирования нашей модели; мы оставляем эти тесты для будущих исследований.

Список используемых источников

- Culkin, R., & Das, S. R. (2017). Machine learning in finance: The case of deep learning for option pricing. *Journal of Investment Management*, 15(4), 92–100.
- De Spiegeleer, Madan, Reyners, Schoutens, 2018.
- Brooks, C. (1997). Linear and non-linear (non-) forecastability of high-frequency exchange rates. *Journal of Forecasting*, 16(2), 125–145.
- A.Kanas, 2003. Non-linear forecasts of stock returns <https://doi.org/10.1002/for.858>
- Lin, J.-L., & Granger, C. W. (1994). Forecasting from non-linear models in practice. *Journal of Forecasting*, 13(1), 1–9.
- Henrique, Sobreiro, Kimura, 2019.
- Mishra, S., & Padhy, S. (2019). An efficient portfolio construction model using stock price predicted by support vector regression. *The North American Journal of Economics and Finance*.
- Ma, Y., Han, R., & Wang, W. (2021). Portfolio optimization with return prediction using deep learning and machine learning. *Expert Systems with Applications*, 165, Article 113973.
- Moscattelli, M., Parlapiano, F., Narizzano, S., & Viggiano, G. (2020). Corporate default forecasting with machine learning. *Expert Systems with Applications*, 161, Article 113567.
- Golbayani, P., Florescu, I., & Chatterjee, R. (2020). 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*, 54, Article 101251.
- Min, J. H., & Lee, Y.-C. (2005). Bankruptcy prediction using support vector machine with optimal choice of kernel function parameters. *Expert Systems with Applications*.
- Barboza, F., Kimura, H., & Altman, E. (2017). Machine learning models and bankruptcy prediction. *Expert Systems with Applications*, 83, 405–417.
- Chen, A.-S., Leung, M. T., & Daouk, H. (2003). Application of neural networks to an emerging financial market: Forecasting and trading the Taiwan stock index. *Computers & Operations Research*, 30(6), 901–923.
- Le, H. H., & Viviani, J.-L. (2018). Predicting bank failure: An improvement by implementing a machine-learning approach to classical financial ratios. *Research in International Business and Finance*, 44, 16–25.
- Du Jardin, P. (2010). Predicting bankruptcy using neural networks and other classification methods: The X Международная научная конференция "Информационные технологии интеллектуальной поддержки принятия решений" Уфа-Баку-Чандigarх, 2024
- influence of variable selection techniques on model accuracy. *Neurocomputing*, 73(10–12), 2047–2060.
- Sureshkumar, K., & Elango, N. (2012). Performance analysis of stock price prediction using artificial neural network. *Global Journal of Computer Science and Technology*, 12(1), 18–25.
- S. Galeshchuk (2016) Neural networks performance in exchange rate prediction. <https://doi.org/10.1016/j.neucom.2015.03.100>
- Kneip, A., & Utikal, K. J. (2001). Inference for density families using functional principal component analysis. *Journal of the American Statistical Association*, 96(454), 519–542.
- Kim, J.-M., Kim, D. H., & Jung, H. (2020). Modeling non-normal corporate bond yield spreads by copula. *North American Journal of Economics and Finance*, 53, 1–15.
- Boneh, S., & Mendieta, G. R. (1992). Regression Modeling Using Principal Components. In 4th Annual Conference on Applied Statistics in Agriculture Manhattan, KS, USA.
- Mevik, B.-H., Wehrens, R., & San Michele all'Adige, T. (2015). Introduction to the pls package. Help Section of the "Pls" Package of RStudio Software, 1–23.
- Kim, J.-M., & Jung, H. (2019). Predicting bid prices by using machine learning methods. *Applied Economics*, 51(19), 2011–2018.
- Kim, J.-M., & Jung, H. (2019). Predicting bid prices by using machine learning methods. *Applied Economics*, 51(19), 2011–2018.
- Friedman, J. H. (1991). Multivariate adaptive regression splines. *The Annals of Statistics*, 1–67.
- Vapnik, V. (1998). *Statistical Learning Theory*, Vol. 3.
- Hsu, C.-W., & Lin, C.-J. (2002). A simple decomposition method for support vector machines. *Machine Learning*, 46(1–3), 291–314.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32
- Hornik, K., Stinchcombe, M., & White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5), 359–366.
- Kim, D. H., & Stock, D. (2014). The effect of interest rate volatility on corporate yield spreads on both noncallable and callable bonds. *Journal of Corporate Finance*, 26, 20–35.
- Bessembinder, H., Kahle, K. M., Maxwell, W. F., & Xu, D. (2009). Measuring abnormal bond performance. *Review of Financial Studies*, 22
- Breeden, D. (2011). A Stocks, Bonds and Consumers Leading Index (SBCLI): Consumer Behavior as a Leading Indicator. In World Finance Conference Rhodes, Greece.
- Campbell, J. Y., & Taksler, G. B. (2003). Equity volatility and corporate bond yields. *The Journal of Finance*, 58(6), 2321–2350.