ISSN 2658-5014 (Print) СИИТ ISSN 2686-7044 (Online)
http://siit.ugatu.su 2026. Т. 8, № 5(29)
СИСТЕМНАЯ ИНЖЕНЕРИЯ И ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ
Научная статья

УДК 004.8 DOI: 10.54708/SIIT-2026-no5-p33 EDN: ZPQROJ

Применение методов роевого интеллекта при обучении моделей управления рисками сложных организационных систем (на примере инвестиционных портфелей)

О. В. Кондратьева • О. Н. Сметанина

Уфимский университет науки и технологий

Необходимость интеллектуальной поддержки лица, принимающего решения на фондовой бирже, определила актуальность работы. Инвестор, руководствуясь целью получить как можно больший доход при минимальном риске денежных потерь, всегда будет стоять перед проблемой выбора эффективного на текущий момент решения о вложении инвестиций. Риск – это категория неопределенности в получении доходов, которую необходимо учитывать при формировании инвестиционного портфеля. Современные инструменты оценки риска имеют слабые стороны и их применение не эффективно, поэтому в статье предлагается использование новых подходов к оценке риска, которые бы учли недостатки существующих методик, а именно, комбинированных индексно-энтропийных мер риска, которые сочетают в себе энтропийную меру риска и другие индексные меры. Для практического использования предложенных моделей оценки риска были настроены их весовые коэффициенты посредством решения задачи машинного обучения с учителем, где целевым признаком является доходность портфеля, характеристическим признаком – значение меры риска, а элементами – различные альтернативные решения. Для этого выбран метод, позволяющий решить поставленную задачу, исходя из особенностей алгоритмов роевого интеллекта. Разработан алгоритм обучения модели оценки риска с помощью метода роя частиц и проведена оценка точности работы модели с помощью метрики Presicion на тестовой выборке.

Роевой интеллект; метод роя частиц; машинное обучение с учителем; модель оценки риска; портфель ценных бумаг.

Введение

Современное состояние на фондовой бирже характеризуется высокой неустойчивостью, ростом неопределенности и сложным процессом принятия решений. Но стабильная работа сложной организационной системы требует удержания низкого уровня волатильности. Систематический риск является объективным фактором, который не поддается управлению, поэтому необходимо регулировать несистематический риск сложной организационной системы путем диверсификации инвестиционного портфеля, так как балансировка инвестиционного портфеля является одним из механизмов управления на фондовом рынке.

Эффективность работы всей организационной системы напрямую связана с механизмами вознаграждения (прибыль от инвестиций) и наказания (риски принять решение, которое приведет к убыткам) участников фондового рынка. Риск – это мера неопределенности в получении доходов инвестором, которую необходимо рассчитывать при принятии решений о составе инвестиционного портфеля. В зависимости от текущих и стратегических целей инвесторов инвестиционные портфели могут различаться по доходности и риску. Как правило, ценные бумаги, обладающие низким показателем риска, имеют небольшую ожидаемую доходность,

Кондратьева О. В., Сметанина О. Н. Применение методов роевого интеллекта при обучении моделей управления рисками сложных организационных систем (на примере инвестиционных портфелей) // СИИТ. 2026. Т. 8, № 5(29). С. 33-42. DOI: 10.54708/SIIT-2026-no5-p33. EDN: ZPQROJ.

Kondrateva O. V., Smetanina O. N. “Application of swarm intelligence methods in training risk management models for complex organizational systems (using investment portfolios as an example).” // SIIT. 2026. Vol. 8, no. 5(29), pp. 33-42. DOI: 10.54708/SIIT-2026-no5-p33. EDN: ZPQROJ. (In Russian).

а ценные бумаги, которые могут дать большой доход, имеют значительный риск. Инвестор, руководствуясь естественным желанием получить как можно большой доход при минимальном риске их потерять, всегда будет стоять перед проблемой выбора эффективного на текущий момент инвестиционного портфеля.

Анализ известных моделей оценки риска

Согласно современной портфельной теории Марковица, риск рассматривается как дисперсия случайной величины, при предположении о нормальности распределения доходностей, однако эмпирическая функция распределения доходностей асимметрична и имеет «тяжелые» хвосты. Также допущение о том, что корреляция между активами является статической, также не соответствует действительности – во времена падающего тренда на фондовом рынке независимые активы ведут себя так, как будто они имеют сильную корреляцию, то есть применять критерий Марковица в кризисный период становится затруднительно.

Палитра современных инструментов оценки риска расширяется за счет использования новых квантильных, когерентных, выпуклых, аддитивных, индексных и других мер риска, которые являются альтернативой дисперсии и стандартному отклонению, но имеют свои недостатки. С одной стороны, квантильные меры позволяют учитывать размер потенциальных потерь, но с другой – у них нет свойства субаддитивности, поэтому этот показатель недооценивает риск в случае «тяжелых» хвостов распределения доходностей акций. Данный недостаток устраняют когерентные меры риска, но из-за свойства положительной однородности CVaR не может учитывать риск ликвидности, когда значение меры риска изменяется не пропорционально изменению объема портфеля из-за низкой ликвидности акции, входящей в ПЦБ. При больших объемах инвестиций риск ликвидности существенно влияет на суммарный риск всего портфеля, поэтому нельзя его игнорировать при оценке риска.

Свойства субаддитивности и положительной однородности были преобразованы в свойство сублинейности в результате разработки выпуклых мер риска, к которым относится энтропийная мера. Таким образом, преодолевается недостаток класса когерентных мер и учитываются ограничения ликвидности. Энтропия на практике также используется, как мера недостатка информации, которая необходима инвестору для принятия решений. Неопределенность и непредсказуемость будущих котировок в периоды экономических кризисов повышает степень стресса и хаоса на фондовом рынке, поэтому использование энтропийной меры при оценке риска позволит существенно повысить эффективность принимаемых управленческих решений.

Комплексные индексные меры риска (Complex Index Risk Measure, CIRM) содержат коэффициент асимметрии, моду и медиану в качестве мер уровня и формы распределения случайной величины, то есть они учитывают эмпирическое распределение и совмещают в себе различные свойства распределения доходностей, что дает возможность точнее оценить риск, снизить неопределенность и создать более ясную среду для принятия решений.

Перечисленные слабые стороны современных портфельных стратегий требуют формирования новых подходов к оценке риска, которые бы учли недостатки существующих методик, поэтому для интеллектуальной информационной поддержки лица принимающего решения (ЛПР) в [Кон24] применяются комбинированные индексно-энтропийные меры риска, которые сочетают в себе энтропийную меру риска и другие индексные меры, такие как *CVaR* и комплексные индексные меры риска – CIRM_1, CIRM_2, CIRM_3. Выпуклая комбинация энтропийной меры и CVaR зависит от трехмерного векторного параметра $r = (\alpha, \gamma, \lambda)$. Множитель λ является весовым коэффициентом и регулирует долю вклада каждой из мер в состав комбинированной меры.

$$(\mathrm{Entropy} - \mathrm{CVaR})_r = \lambda\rho_\gamma(X) - (1-\lambda)\,\mathrm{CVaR}_\alpha(X).$$

Выпуклая комбинация энтропийной меры и модифицированной CIRM_1 также зависит от трехмерного векторного параметра $r = (\alpha, \gamma, \lambda)$:

$$(\text{Entropy}-\text{CIRM}_1)_r = \lambda\rho_\gamma(X) + (1-\lambda)\left(\frac{1-\text{VaR}_\alpha^-(X)}{\text{VaR}_\alpha^+(X)} - \frac{\text{E}\left[\left(X-\text{E}(X)\right)^3\right]}{\sigma(X)^3}\right).$$

Выпуклые комбинации модифицированных CIRM_2, CIRM_3 и энтропийной меры риска зависят от четырехмерного векторного параметра $r_1 = (\alpha, \gamma, \lambda, \beta)$ и имеют следующий вид:

$$(\text{Entropy}-\text{CIRM}_2)_{r_1} = \lambda\rho_\gamma(X) + (1-\lambda)\left(\frac{1-\text{CVaR}_\alpha^-(X)}{\text{CVaR}_\alpha^+(X)} + \beta\frac{Mo}{\text{CVaR}_\alpha^+(X)} - (1-\beta)\frac{\text{E}\left[\left(X-\text{E}(X)\right)^3\right]}{\sigma(X)^3}\right),$$

$$(\text{Entropy}-\text{CIRM}_3)_{r_1} = \lambda\rho_\gamma(X) + (1-\lambda)\left(\frac{1-\text{CVaR}_\alpha^-(X)}{\text{CVaR}_\alpha^+(X)} + \beta\frac{Me}{\text{CVaR}_\alpha^+(X)} - (1-\beta)\frac{\text{E}\left[\left(X-\text{E}(X)\right)^3\right]}{\sigma(X)^3}\right).$$

Данное сочетание мер риска, с одной стороны, учитывает «тяжелые хвосты» и другие различные свойства распределения ожидаемой доходности благодаря модификации комплексных индексных мер и CVaR, с другой стороны – не игнорирует показатель ликвидности активов и учитывает степень неполноты информации на фондовой бирже благодаря энтропийной мере. Для практического использования комбинированных индексно-энропийных мер требуется подобрать такие коэффициенты (веса) модели оценки риска, чтобы портфель ценных бумаг с минимальным риском в «будущем» позволил получить максимальную доходность от вложений, то есть решить задачу машинного обучения с учителем, где целевым признаком будет контрольное значение доходности, характеристическим признаком – значение меры риска, а элементами – различные по долевой структуре портфели.

Особенности методов роевого интеллекта

Методы роевого интеллекта моделируют коллективное поведение децентрализованных самоорганизующихся живых систем [Ben89], таких как, стаи птиц, косяка рыб, колонии муравьев, роя пчел и т. д. Особенности каждого метода определяют область применения алгоритма, например, алгоритм колонии муравьев – для задач раскраски графа, коммивояжера, анализа образовательных данных [Дюл19], алгоритм роя пчел – для планирования работы тепловых установок [Chan12], для решения задач составления расписаний экзаменов [Alz11]; алгоритм светлячков – для классификации данных и диагностики заболеваний [Hor12], для задач компьютерного зрения [Has11]; метод роя частиц (МРЧ) – для решения задач машинного обучения, оптимизации функций многих параметров и т. д.

Алгоритм роя частиц описывает модель поведения птиц в стае. В каждый момент времени частица характеризуется положением и вектором скорости перемещения, которые обновляются согласно формулам, описанным в [Shi98]. Для каждого положения частицы высчитывается целевая функция, значение которой на первой итерации фиксируется, как лучшее персональное решение, а на последующих итерациях оно может быть обновлено. На каждой итерации среди всех лучших персональных решений выбирается оптимальное, и тогда глобальное решение всего роя может быть обновлено. Таким образом, частицы движутся к наилучшей точке роя, учитывая свой индивидуальный оптимум.

Несмотря на то, что все алгоритмы роевого интеллекта основаны на генерации многоагентной системы, не каждый метод практикоприменим для решения поставленной задачи. Например, пчелиный алгоритм использует концепцию локального поиска, для которого необходимо наличие топологического расстояния на области решений для корректного определения подобластей, что создает трудности при использовании этого алгоритма без модификации. Результатом муравьиного алгоритма является оптимальный путь (граф) с несколькими узлами, которым при решении поставленной задачи соответствовали бы различные вектора коэффициентов модели. На выходе формировался бы пул альтернатив, что не позволило бы предложить лицу, принимающему решение, оптимальный вариант и реализовать информационную поддержку без применения дополнительных инструментов.

В случае использовании метода роя частиц итерационная природа поиска позволяет не переобучить модель, а остановить работу алгоритма на конкретном шаге. Нахождение наилучшего решения частицы производится на интервале обучающей выборки, а наилучшее решение всего роя используется для валидации параметров модели. Таким образом, анализ роевых алгоритмов показал, что для решения задачи машинного обучения с учителем наибольшее преимущество имеет метод роя частиц, согласно области применения и соответствия особенностей алгоритма специфике рассматриваемой задачи.

Применение алгоритма роя частиц при обучении модели оценки риска

Пространством поиска является симплекс $U = [0,3]^N$, а положение агента (частицы) в пространстве соответствует определенной комбинации коэффициентов меры риска, то есть количество компонентов частицы $x_{i,t}^j$ соответствует числу параметров обучаемой модели. Частица роя характеризуется не только вектором коэффициентов, но и долевой структурой решения, которое зафиксировано для каждого агента на всех итерациях обучения модели.

Целевой функцией, которую необходимо минимизировать, является модель оценки финансового риска или комбинированные индексно-энтропийные меры риска, описанные выше: $\min\limits_{x \in U} F(x)$, здесь x – вектор коэффициентов модели. Целевая функция отражает, чему равна мера риска при определенном положении агента в пространстве поиска.

Итак, $x_{i,t}$ и $v_{i,t}$ – векторы, характеризующие положение и скорость i-го агента ($i = \overline{1,Q}$), Q – число альтернативных решений из эффективного множества. На компоненты вектора $x_{i,t}^j$ накладываются ограничения, которые отражают интервал, на котором будет варьироваться параметр:

$$\begin{cases} 0.01 < x_{i,t}^{\alpha} \le 0.2, \\ 0.01 < x_{i,t}^{\gamma} \le 3, \\ 0.01 < x_{i,t}^{\beta} \le 1, \\ 0 \le x_{i,t}^{\lambda} \le 1. \end{cases}$$

Координаты положения агента в пространстве поиска и его скорость рассчитываются по формулам [Shi98]:

$$x_{i,t+1} = v_{i,t+1} + x_{i,t},$$
$$v_{i,t+1} = c_0 v_{i,t} + c_1 \mathrm{Rand}(\,)\left(p_{i,t} - x_{i,t}\right) + c_2 \mathrm{Rand}(\,)\left(g_t - x_{i,t}\right),$$

где $p_{i,t}$ – координаты вектора коэффициентов модели, при которых достигается лучшее персональное значение меры риска i-го агента на итерации t; g_t – координаты вектора коэффициентов модели, при которых достигается лучшее глобальное значение целевой функции среди всех агентов роя.

В отличие от классического алгоритма роя частиц предлагается производить поиск наилучших решений частицы, рассчитывая целевую функцию на интервале обучающей выборки, а наилучшее глобальное решение всего роя использовать для валидации процесса обучения модели. Таким образом, критерием остановки работы алгоритма, помимо заданного количества итераций, будет ситуация, когда на интервале валидационной выборки алгоритм достигнет такого наилучшего решения всего роя, которое будет не менее контрольного значения целевого признака.

В работе используется подход машинного обучения, при котором модель обучается на размеченных данных, то есть применяется обучение с учителем. Метками являются альтернативные решения, из которых выделяется эффективное множество, которому соответствует максимальное значение целевого признака. Исторические данные служат базой для формирования обучающей выборки, элементами которой являются значения доходностей эффективных ПЦБ.

Обученная модель оценки риска применяется на интервале тестовой выборки для поиска эффективного решения. В силу того, что при тестировании модели на вход подаются методом прямого перебора все возможные альтернативные решения, а не единичный вариант входных данных, результатом расчета целевой функции будет множество значений, из которого выбирается минимальное, а соответствующее ему альтернативное решение проверяется на предмет отклонения от контрольного значения целевого признака. Таким образом, решается задача классификации, когда, найденное с помощью модели оценки риска, решение относится к одному из двух классов – эффективных или не эффективных, согласно контрольному значению целевого признака.

Алгоритм обучения модели оценки риска с помощью роевого интеллекта (рис. 1) происходит следующим образом:

Шаг 1. Предобработка исторических данных – обработка значений дневных котировок ценных бумаг включает в себя проверку на пустые значения. Такая ситуация может быть в случае, если в этот день не было сделок по данному активу, тогда процедура «Заполнить пустые значения» заполнит цену акции ценой предыдущего (или следующего, если пустой первый элемент интервала) торгового дня.

Шаг 2. Формирование выборки – исторические данные разделяются на три кластера в соответствии с характером тренда и для каждого кластера формируется обучающая, валидационная и тестовая выборки. Причем в рамках временного ряда обучающая выборка должна предшествовать валидационной. Обучение, валидация и тестирование модели происходит внутри кластера, потому что модель, обученная, например, на данных, соответствующих падающему фондовому рынку, не будет эффективна в условиях экономического роста, и наоборот.

Шаг 3. Разметка данных – генерация методом прямого перебора всех возможных комбинаций с шагом 0,1 структур альтернативных решений, т. е. формируется вектор $\mathrm{STR}_i(\mathrm{str}_{i,1}, \mathrm{str}_{i,2}, \dots, \mathrm{str}_{i,n})$, где $\mathrm{str}_{i,s}$ – доля *s*-го элемента в *i*-м решении $(s = \overline{1,n}, i = \overline{1,m})$, т. е. $\sum_{s=1}^{n} \mathrm{str}_{i,s} = 1$, где n – размерность листинга решения. Расчет целевого признака (ЦП) на данных валидационной выборки альтернативных решений и исключение из рассмотрения, если значение ЦП менее 1. Формирование эффективного множества решений, путем ранжирования по значению ЦП и выделение 25% элементов с максимальным значением, т. е. выбранным альтернативным решениям присвоен статус «эффективный». Определить нижнюю границу целевого признака ($d_{\min}$), которой принадлежат эффективные решения.

Шаг 4. Создание роя частиц – сгенерировать начальный вектор коэффициентов модели оценки риска и скорость для каждого агента роя с помощью случайных векторов $x_{i,1}$ и $v_{i,1}$, имеющих многомерное равномерное распределение, с учетом ограничений, описанных выше. Число решений, принадлежащих эффективному множеству, соответствует количеству агентов в рое (Q).

Шаг 5. Определение начальных значений (первая итерация, *t=1*) наилучшего персонального решения частицы и наилучшего глобального решения всего роя – рассчитать целевую функцию $F(x_{i,1})$, используя датасет обучающей выборки, и зафиксировать ее значение как лучшее персональное значение портфеля на начальном этапе: $p_{i,1} \leftarrow F(x_{i,1})$. Глобальному оптимуму присвоить минимальное значение из персональных лучших значений частиц: $g_1 \leftarrow \min_{x \in U} F(x_{i,1})$, и зафиксировать структуру *i*-го решения: $\mathrm{gstr}_1 \leftarrow \mathrm{STR}_i$.

Шаг 6. Проверка условия остановки алгоритм – рассчитать значение целевого признака $P(\mathrm{gstr}_t)$ наилучшего глобального решения роя на интервале валидационной выборки. Если $P(\mathrm{gstr}_t) \geq d_{\min}$, либо если $t > k$, то перейти на *Шаг 11*, в противном случае, перейти к следующему шагу.

Шаг 7. Переход на следующую итерацию ($t = t + 1$). Рассчитать скорость $v_{i,t}$ для каждой частицы роя. Обновить положение частицы $x_{i,t}$, т. е. вычислить новую комбинацию весов модели.

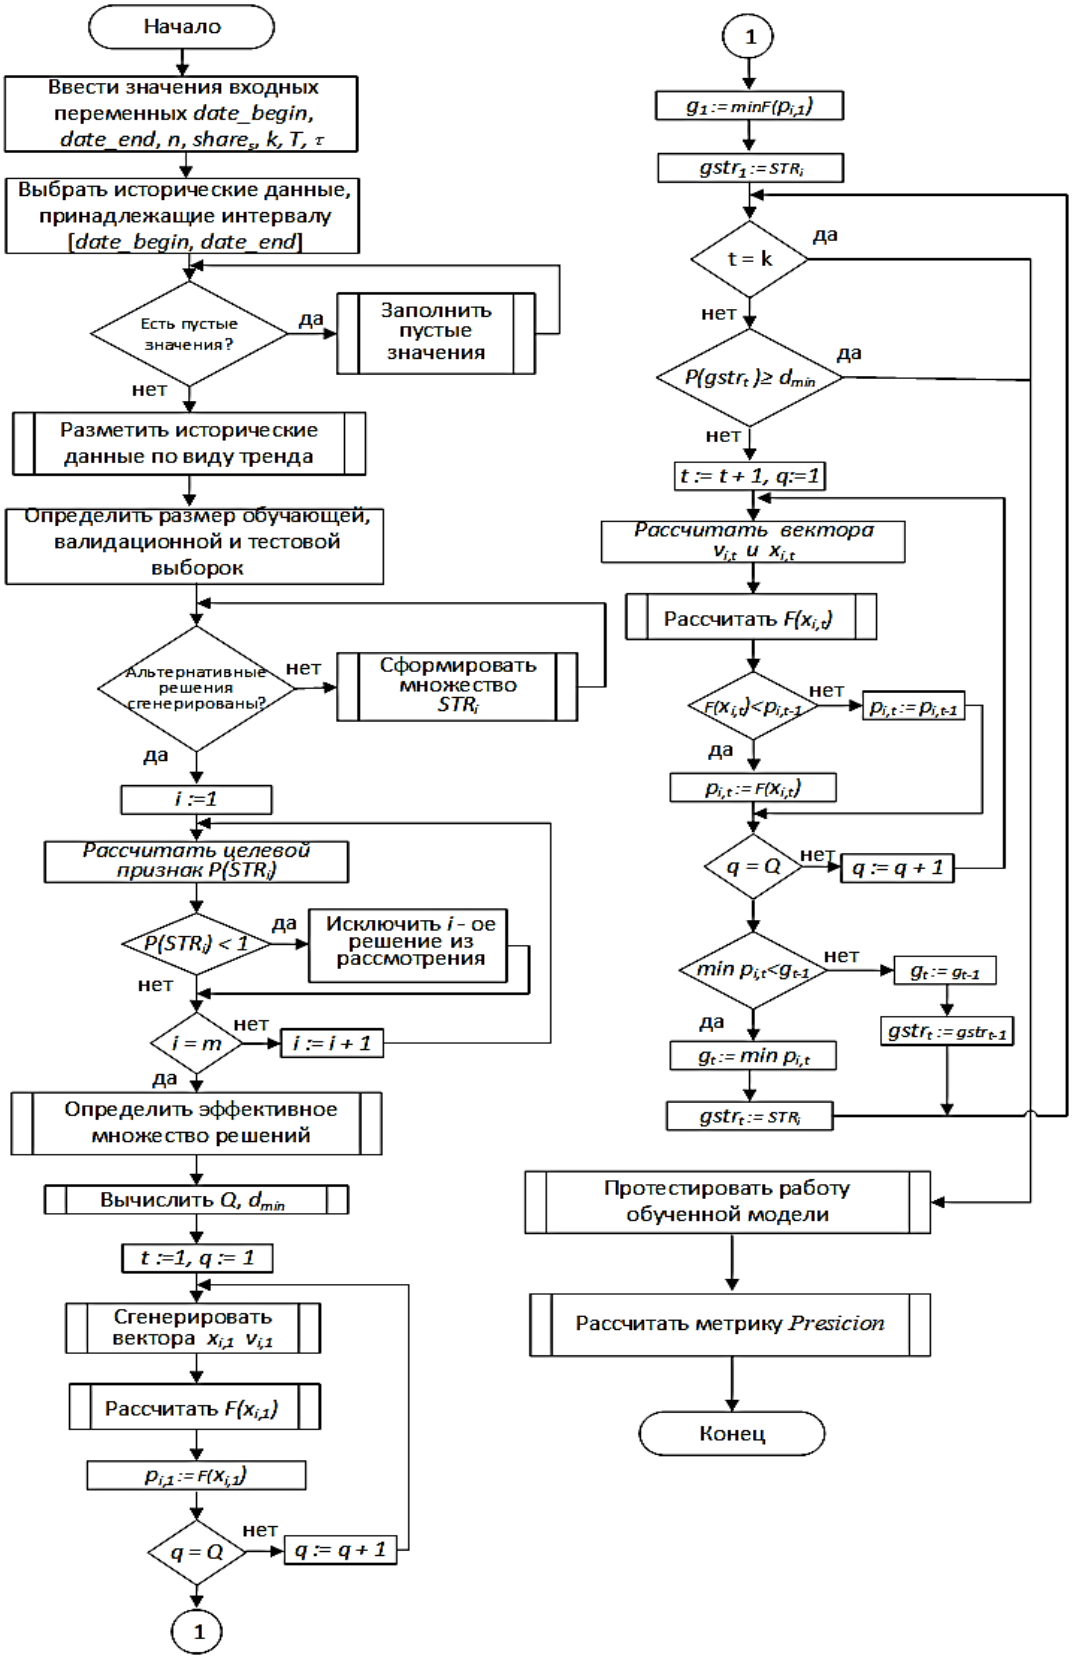


Рис. 1. Блок-схема алгоритма обучения модели оценки риска с применением роевого интеллекта

Шаг 8. Определение лучшего персонального значения агента. Рассчитать для каждой частицы значение целевой функции. Если $F(x_{i,t}) < p_{i,t-1}$, то обновить лучшее персональное значение частицы: $p_{i,t} \leftarrow F(x_{i,t})$, в противном случае $p_{i,t} = p_{i,t-1}$.

Шаг 9. Определить глобальное решение всего роя: $\min p_{i,t}$. Если $\min p_{i,t} < g_{t-1}$, то обновить лучшее решение роя $g_t \leftarrow \min p_{i,t}$ и зафиксировать структуру i-го решения: $\text{gstr}_t \leftarrow \text{STR}_i$, в противном случае $g_t = g_{t-1}$ и $\text{gstr}_t = \text{gstr}_{t-1}$.

Шаг 10. Перейти на *Шаг 6.*

Шаг 11. Оценить качество работы обученной модели на тестовой выборке. Вычислить $d_{\min}$ на данных тестовой выборки. Разделить тестовую выборку на два интервала T и τ. Используя обученную модель оценки риска, найти такой компонент вектора STR_i, которому соответствует минимальное значение риска на интервале T. Рассчитать значение целевого признака найденного i-ого решения на интервале τ. Если $P(\text{str}_i) \geq d_{\min}$, то альтернативное решение классифицировать, как эффективное. Провести *Шаг 11* для различных по составу листингов и рассчитать метрику Presicion.

Для оценки эффективности работы алгоритма обучения модели был проведен вычислительный эксперимент. В кластере восходящего тренда обучающая выборка включала данные за период от 03.01.2023 до 31.10.2023, валидационная выборка – за период от 01.11.2023 до 29.12.2023, тестовая выборка – за период от 04.01.2024 до 27.12.2024. В кластере нисходящего тренда: обучающая выборка – за период от 05.01.2022 до 31.10.2022, валидационная выборка – за период от 01.11.2022 до 30.12.2022, тестовая выборка – за период от 03.01.2025 до 23.12.2025. Листинг (share_s) состоял из 6 элементов ($n = 6$).

Методом прямого перебора сгенерированы 126 альтернатив ($m = 126$), различающихся по долевой структуре, на сетке от 0.1 до 0.9 с шагом 0.1, чтобы альтернативные решения соответствовали свойству диверсифицированности, что является фактором снижения риска. Значения целевого признака альтернативных вариантов решений, рассчитанные на интервале валидационной выборки, представлены на диаграмме рассеяния (рис.2).

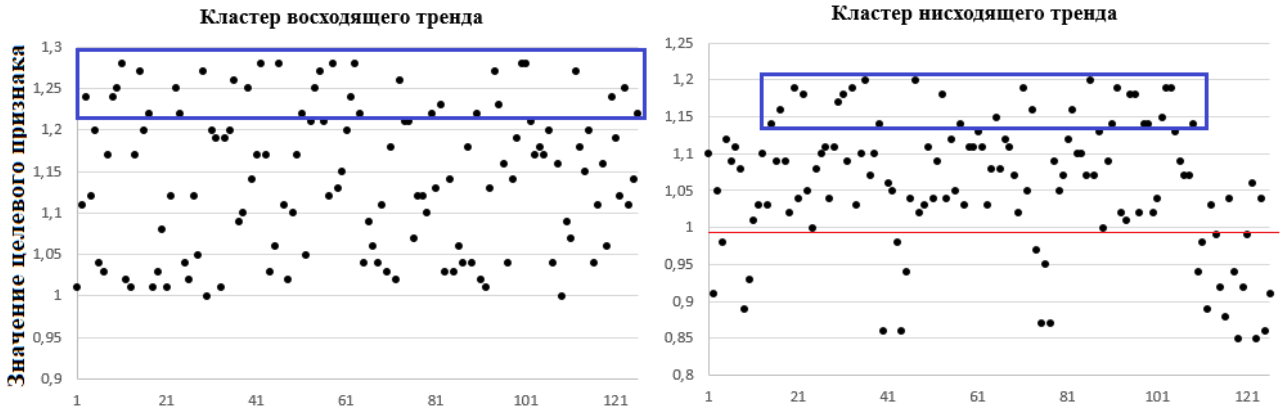


Рис. 2. Эффективное множество альтернативных решений

Эффективное множество (рис.2, выделено синей рамкой) в кластере восходящего тренда (Кл1) состояло из 32 элементов, значение целевого признака которых варьировалась от 22% до 28%. В кластере нисходящего тренда (Кл2) на третьем шаге алгоритма были исключены из рассмотрения 25 элементов (рис.2, ниже красной линии), так как они не соответствуют критерию целевого признака, а модель обучается только на позитивных прецедентах. В условиях экономического кризиса эффективное множество состояло из 27 элементов, значение целевого признака которых варьировалась от 14% до 20%.

Таким образом, была определена нижняя граница целевого признака: $d_{\min} = 0.22$ – для Кл1 и $d_{\min} = 0.14$ – для Кл2. А также количество частиц в рое: $Q_{\text{Кл1}} = 32$ – для периода восходящего тренда, и $Q_{\text{Кл2}} = 27$ – для периода нисходящего тренда. Одним из критериев остановки является количество пройденных итераций $k = Q \cdot 5$, тогда $k_{\text{Кл1}} = 160$, $k_{\text{Кл2}} = 135$.

В [Бро21] представлен результат настройки коэффициентов функции скорости для сбалансированной работы алгоритма. Запуск процесса обучения модели оценки риска производился

в трех версиях, опираясь на откалиброванные значения c_0, c_1, c_2, для следующих комбинаций (0,829; 1,99; 1,99), (0,929; 1,49; 1,49) и (0,129; 1,69; 1,69).

В заключении каждой итерации работы роевого алгоритма текущее значение вектора параметров модели, зафиксированное как наилучшее решение роя, проходит валидацию. В случае успешной валидации, когда обученная модель позволила найти такое решение, которое относится к классу эффективных, обучение модели останавливается. В процессе вычислительного эксперимента было обучено четыре модели (согласно количеству комбинированных индексно-энтропийных мер риска) на датасетах двух кластеров (Кл1 и Кл2). Так как используемый метод является стохастическим, то скорость сходимости алгоритма обучения (рис. 3) измерялась по нескольким независимым запускам согласно среднему числу итераций, пройденных роевым алгоритмом, до момента, когда модель позволят найти решение, соответствующее заданному порогу точности. Показателем стабильности сходимости алгоритма является стандартное отклонение от среднего числа итераций (см. число на вершинах столбцом гистограммы на рис. 3).

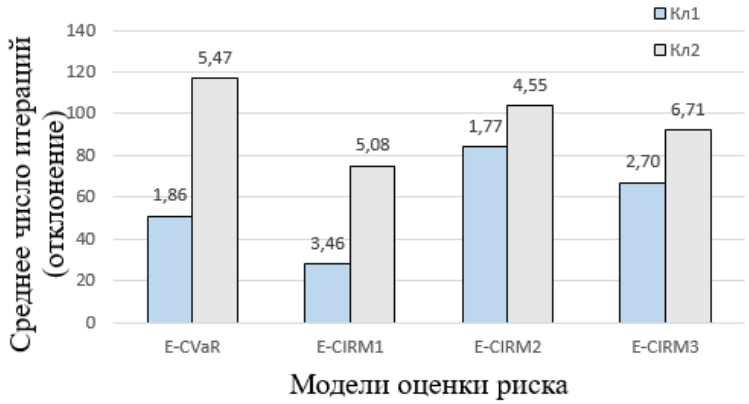


Рис. 3 Скорость сходимости и стабильность алгоритма обучения моделей риска.

Минимальная средняя скорость сходимости, равная 28, говорит о сниженном риске преждевременной сходимости благодаря тому, что на 4-ом шаге алгоритма используется многомерное равномерное распределение по пространству поиска для формирования роя, то есть алгоритм исследует обширную область и не «застревает» в локальном оптимуме.

Точность работы модели оценивалась с точки зрения корректности классификации найденного решения, как эффективного. Метрика Presicion показывает процент кейсов, когда найденное, с помощью обученной модели оценки риска, решение действительно принадлежит эффективному множеству (табл. 1).

Таблица 1

Результаты обучения модели оценки риска

Модель оценки риска	Вектор коэффициентов модели $(\alpha, \gamma, \beta, \lambda)$	Presicion	Вид тренда
$(\mathrm{Entropy}-\mathrm{CIRM}_1)_{r_6}$	(0.14, 0.85, – , 0.3)	0.97	растущий
$(\mathrm{Entropy}-\mathrm{CVaR})_{r_{12}}$	(0.2, 2.29, – , 0.9)	0.91	растущий
$(\mathrm{Entropy}-\mathrm{CIRM}_2)_{r_4}$	(0.04, 2.25, 0.64, 0.8)	0.93	растущий
$(\mathrm{Entropy}-\mathrm{CIRM}_3)_{r_9}$	(0.15, 0.8, 0.39, 0.1)	0.94	растущий
$(\mathrm{Entropy}-\mathrm{CIRM}_1)_{r_{15}}$	(0.13, 2.31, – , 0.6)	0.92	падающий
$(\mathrm{Entropy}-\mathrm{CVaR})_{r_3}$	(0.16, 0.33, – , 0.8)	0.86	падающий
$(\mathrm{Entropy}-\mathrm{CIRM}_2)_{r_7}$	(0.06, 0.62, 0.2, 0.3)	0.89	падающий
$(\mathrm{Entropy}-\mathrm{CIRM}_3)_{r_2}$	(0.2, 0.45, 0.27, 0.1)	0.85	падающий

Заключение

Разработан алгоритм обучения модели оценки финансового риска с использованием метода роя частиц. Проведено обучение модели на размеченных данных с целью оценить эффективность работы алгоритма. Быстрее всего на обоих кластерах данных обучилась модель E-CIRM$_1$. При обучении всех четырех моделей алгоритм достиг контрольных значений на итерациях от 28 до 84 (для кластера Кл1) и от 75 до 117 (для кластера Кл2), то есть работа алгоритма была остановлена, исходя из найденного эффективного решения, которое подтверждено на валидационной выборке, а не принудительно по критерию длины пройденного пути (k).

Алгоритм демонстрирует устойчивую сходимость – максимальная робастность достигалась при обучении моделей E-CVaR и E-CIRM$_2$ на данных кластера Кл1(стандартное отклонение равно 1.86 и 1.77). Показатель стабильности обучения моделей на данных кластера Кл2 варьируется от 4.55 до 6.71, что соответствует низкому разбросу и говорит о надежности поиска эффективных решений при каждом запуске алгоритма.

Результаты применения обученной модели показали, что на кластере Кл1 роевой интеллект позволил подобрать веса моделей так, что эффективное решение достигается в случаях от 91% до 97%, а для кластера Кл2 модель работает с точностью от 85% до 92%. Даже в условиях экономического кризиса (Кл2) использование метода роя частиц позволило настроить модель Entropy – CIRM$_1$ так, что доля верных прогнозов высока.

Список литературы | References

[Alz11] Alzaqebah M., Abdullah S. Comparison on the selection strategies in the artificial bee colony algorithm for examination timetabling problems // Int J Soft Comput Eng. 2011. № 1. pp. 158–163. https://dl.icdst.org/pdfs/files/d7c910681ae68a109db5c2b7dbb0894b.pdf.

[Ben89] Beni G., Wang J. Swarm Intelligence in Cellular Robotic Systems // Robots and biological systems: towards a new bionics? Proc. of the NATO Advanced Workshop, Toscana, Italy, 1989. pp. 703-712. 10.1007/978-3-642-58069-7_38.

[Chan12] Chandrasekaran K., Hemamalini S., Simon S., Padhy N. Thermal unit commitment using binary/real coded artificial bee colony algorithm // Electric Power Syst Res 2012. 84(1). pp. 109–119. 10.1016/j.epsr.2011.09.022.

[Has11] Hassanzadeh T., Vojodi H. and Moghadam A. M. E. An image segmentation approach based on maximum variance intra-cluster method and firefly algorithm // Proc. of 7th Int. Conf. on Natural Computation (ICNC). 2011. pp. 1817-1821. 10.1109/ICNC.2011.6022379.

[Hor12] M.-H. Horng, Y.-X. Lee, M.-C. Lee and R.-J. Liou, Firefly metaheuristic algorithm for training the radial basis function network for data classification and disease diagnosis, in: Theory and New Applications of Swarm Intelligence (Edited by R. Parpinelli and H. S. Lopes). 2012. pp. 115-132. 10.5772/39084.

[Shi98] Shi Y., Eberhart R. A modified particle swarm optimizer // Proc. of the IEEE International Conference on Evolutionary Computation Proceedings. 1998. PP. 69–73. 10.1109/ICEC.1998.699146.

[Бро21] Бронштейн Е.М., Кондратьева О.В. Методика применения роевого интеллекта при управлении формированием портфеля ценных бумаг // Вестник РосНОУ. Сложные системы модели, анализ и управление. 2021. №3, С.70-79. MRFEST. [E.M. Bronshtein, O.V. Kondrateva The method application of swarm intelligence in managing the securities portfolio formation // Vestnik of Russian New University. Series "Complex systems: models, analysis, management". 2021. №3, PP.70-79. MRFEST. (In Russian).]

[Дюл19] Дюличева Ю.Ю. Алгоритмы роевого интеллекта и их применение для анализа образовательных данных // Открытое образование. 2019. Т. 23, №5. С. 33-43. RGICOG. [Dyulicheva Y.Y. The swarm intelligence algorithms and their application for the educational data analysis // Open Education. 2019. Vol. 23, no. 5. pp. 33-43. RGICOG. (In Russian).]

[Кон24] Кондратьева О.В., Сметанина О.Н. Концепция интеллектуальной информационной поддержки принятия решений частного инвестора при формировании портфеля ценных бумаг // Прикаспийский журнал: управление и высокие технологии. 2024. № 4 (68). С. 92-101. KJKEWR. [The intellectual information support concept for decision-making in the securities portfolio formation by a private investor // CASPIAN JOURNAL: Control and High Technologies. 2024. 4 (68). pp. 92-101. KJKEWR. (In Russian).]

ОБ АВТОРАХ | ABOUT THE AUTHORS

КОНДРАТЬЕВА Ольга Владимировна
Уфимский университет науки и технологий, Россия.
kondr_o@mail.ru ORCID: 0000-0003-1448-3747.
Ст. преп. каф. автоматизированных систем управления. Дипл. экон.-информатик (Уфимск. гос. авиац. техн. ун-т). Иссл. в обл. интелл. поддержки принятия решений.

СМЕТАНИНА Ольга Николаевна
Уфимский университет науки и технологий, Россия.
smetanina.on@ugatu.su ORCID: 0000-0001-6970-1110.
Проф. каф. вычислительной математики и кибернетики. Дипл. инж.-электрик (Уфимск. авиац. ин-т). Д-р техн. наук по управлению в соц. и экон. системах (Уфимск. гос. авиац. техн. ун-т). Иссл. в обл. интелл. поддержки принятия решений.

KONDRATEVA Olga Vladimirovna
Ufa University of Science and Technology, Russia.
kondr_o@mail.ru ORCID: 0000-0003-1448-3747.
Senior Lecturer of the Automated Control Systems dept. Dipl. Economist-Informatician (Ufa State Aviation Tech. Univ.). Research in the field of intelligent decision support.

SMETANINA Olga Nikolaevna
Ufa University of Science and Technology, Russia.
smetanina.on@ugatu.su ORCID: 0000-0001-6970-1110.
Prof. of Computational Mathematics and Cybernetics Dept. Dipl. Eng.-Electrician (Ufa Aviat. Inst.). Dr. Technical Sciences in social and economic management systems (Ufa State Aviat. Tech. Univ.). Research in the field of intelligent decision support.

МЕТАДАННЫЕ | METADATA

Заглавие: Применение методов роевого интеллекта при обучении моделей управления рисками сложных организационных систем (на примере инвестиционных портфелей).

Авторы: Кондратьева О. В., Сметанина О. Н.

Аннотация: Необходимость интеллектуальной поддержки лица, принимающего решения на фондовой бирже, определила актуальность работы. Инвестор, руководствуясь целью получить как можно больший доход при минимальном риске денежных потерь, всегда будет стоять перед проблемой выбора эффективного на текущий момент решения о вложении инвестиций. Риск – это категория неопределенности в получении доходов, которую необходимо учитывать при формировании инвестиционного портфеля. Современные инструменты оценки риска имеют слабые стороны и их применение не эффективно, поэтому в статье предлагается использование новых подходов к оценке риска, которые бы учли недостатки существующих методик, а именно, комбинированных индексно-энтропийных мер риска, которые сочетают в себе энтропийную меру риска и другие индексные меры. Для практического использования предложенных моделей оценки риска были настроены их весовые коэффициенты посредством решения задачи машинного обучения с учителем, где целевым признаком является доходность портфеля, характеристическим признаком – значение меры риска, а элементами – различные альтернативные решения. Для этого выбран метод, позволяющий решить поставленную задачу, исходя из особенностей алгоритмов роевого интеллекта. Разработан алгоритм обучения модели оценки риска с помощью метода роя частиц и проведена оценка точности работы модели с помощью метрики Presicion на тестовой выборке.

Ключевые слова: Роевой интеллект; метод роя частиц; машинное обучение с учителем; модель оценки риска; портфель ценных бумаг.

Язык: Русский.

Статья поступила в редакцию 22 июля 2026 г.

Title: Application of swarm intelligence methods in training risk management models for complex organizational systems (using investment portfolios as an example).

Authors: Kondrateva O. V., Smetanina O. N.

Abstract: The need for intellectual support for decision makers on the stock exchange underpins the relevance of this work. Investors, considering how to achieve greater returns with minimal risk and investment, will always face the challenge of choosing an effective investment solution. Risk is a category of uncertainty in the investor's income, which must be considered when closing an investment portfolio. Current risk assessment tools have weaknesses and are ineffective. Therefore, new approaches to risk assessment are being used in this case. These approaches would highlight the shortcomings of the existing method, namely, combined index-entropy risk measures, which combine an entropy risk measure with other index measures. For the practical use of the proposed risk assessment models, their weighting coefficients were adjusted by solving a supervised machine learning problem, where the target feature is the portfolio return, the characteristic feature is the value of the risk measure, and the elements are various alternative solutions. For this chosen method, the authorization was given to solve the as-signed problem based on the specifics of swarm intelligence algorithms. An algorithm for training a risk assessment model using the particle swarm method was developed, and the accuracy of the model was assessed using the Precision metric on a test sample.

Key words: Swarm intelligence; particle swarm method; supervised machine learning; risk assessment model; securities portfolio.

Language: Russian.

The article was received by the editors on 22 July 2026.