

Автоматизация определения весов критериев в задачах поддержки принятия решений по результатам регрессионного анализа

Automation of determining criterion weights in decision support tasks based on regression analysis results

Комарова / Komarova L.

Любовь Александровна
(starkcom8@mail.ru)
ФГБОУ ВО «Финансовый университет
при Правительстве РФ»,
младший научный сотрудник.
г. Москва

Судаков / Sudakov V.

Владимир Анатольевич
(sudakov@ws-dss.com)
доктор технических наук, профессор.
ФГУ «Федеральный исследовательский центр
Институт прикладной математики
им. М.В. Келдыша РАН»,
ведущий научный сотрудник.
г. Москва

Боев / Bоеv S.

Сергей Федорович
(ris@tstu.tver.ru)
доктор технических наук, доктор экономических
наук, профессор.
ПАО «Акционерная финансовая корпорация
«Система»,
советник председателя.
г. Москва

Зюзин / Zyuzin G.

Глеб Михайлович
(glebzuzin245@gmail.com)
ФГКВООУ ВО «Ярославское высшее военное училище
противовоздушной обороны» МО РФ,
заведующий кабинетом по метрологии
и радиоизмерениям.
г. Ярославль

Ключевые слова: многокритериальное принятие решений – multicriteria decision-making; весовые коэффициенты критериев – criteria weight coefficients; автоматизация назначения весов – automated weight assignment; машинное обучение – machine learning; приоритизация альтернатив – alternative prioritization.

В работе предложен и экспериментально исследован подход к определению весов критериев в задачах многокритериальной поддержки принятия решений, основанный на использовании методов машинного обучения и генеративных языковых моделей. В отличие от классических экспертных методов, предложенная методика формализует задачу назначения весов как задачу регрессии, в которой каждый критерий описывается совокупностью статистических характеристик распределения его оценок по множеству альтернатив. Проведённые эксперименты показали, что ML-подход, в частности Ridge-регрессии, обеспечивает более точное восстановление эталонных весов по сравнению с существующими методами.

This paper proposes and experimentally investigates an approach for determining criterion weights in multi-criteria decision support problems based on machine learning methods and generative language models. Unlike classical expert-based techniques, the proposed methodology formalizes the weight assignment task as a regression problem, where each criterion is represented by a set of statistical characteristics of the distribution of its scores across a set of alternatives. Experimental results show that the ML-based approach—specifically Ridge regression—reconstructs reference weights more accurately than existing methods.

Введение

В задачах поддержки принятия решений одним из самых ответственных этапов является присвоение весовых коэффициентов важности критериев, на основе которых выстраивается объективные числовые

показатели решения. При наличии ошибки в весовых коэффициентах не получится получить объективную оценку альтернатив для диспетчера объекта критической инфраструктуры (ОКИ).

Традиционные подходы полагаются на субъективное мнение экспертов при определении важности критериев.

риев [1]. Такой подход часто не позволяет объективно оценить альтернативы и не обеспечивает правильный расчет суммы всех взвешенных оценок решений из-за того, что разные эксперты могут назначить существенно разные веса одному и тому же набору критериев. В результате определение весов критериев влияет на точность и надёжность принимаемого решения, необходимую для снижения вероятности аварийных ситуаций на ОКИ в распределительных сетях.

Определение весовых коэффициентов критериев – один из ключевых и самых сложных этапов многокритериального принятия решений. Известно, что итоговые рейтинги альтернатив зависят от выбранных весов критериев, поэтому простое присвоение всем критериям равных весов обычно считается неоптимальным. В литературе методы оценки значимости критериев принято классифицировать на три группы: субъективные, объективные и интегрированные (гибридные) [4].

В частности, возможны ситуации, при которых критерии часто коррелированы, данные могут быть шумными и неполными, а приоритеты зависят от режима сети и критичности отключённых потребителей. По этой причине современные методы поддержки принятия решений (ППР) [5, 6] должны обладать высокой устойчивостью к шуму, адаптивностью к разным сценариям аварии и воспроизводимостью результатов при идентичных исходных данных. Ниже приведён систематизированный обзор принципов работы каждой группы методов, а также их достоинств, недостатков, областей применения и сравнительных характеристик.

Субъективные методы полностью опираются на мнения и предпочтения экспертов или лиц, принимающих решение (ЛПР) при назначении весов критериев. В таком подходе не используется работа с данными. Иными словами, веса определяются априори на основе суждений, без прямого вычисления из данных. Фактически ответственность за значимость критериев целиком лежит на эксперте. Используются различные техники экспертной оценки: прямое ранжирование, когда эксперт непосредственно ранжирует критерии по важности, или метод парных сравнений (аналитический иерархический процесс Саати) [7–10], когда эксперт попарно сравнивает критерии по относительной важности, после чего вычисляются веса, как компоненты собственного вектора матрицы парных сравнений. Данные методы применимы даже при отсутствии данных по альтернативам, поэтому широко используются в стратегических, социально-экономических задачах, где критерии трудно формализовать количественно. Экспертные методы гибки и понятны ЛПР, а такие популярные техники, как АНР (Analytic Hierarchy Process, метод анализа иерархий) обеспечивают прозрачный и иерархичный процесс оценки. Преимуществом методов является то, что они позволяют учитывать качественные факторы и интуицию специалиста, но это и главный их недостаток,

так как они зависимы от человеческого фактора и, следовательно, субъективны.

Объективные методы не требуют участия экспертов при вычислении весовых коэффициентов [4]. Веса выводятся автоматически из исходных данных так называемой матрицы решений, содержащей оценки всех альтернатив по всем критериям [7, 8]. Предполагается, что информация, заложенная в данных, отражает относительную важность критериев. Обычно такие методы измеряют степень вариативности или дисперсии значений критериев: считается, что критерий, значения которого значительно различаются между альтернативами, обладает большей способностью влиять на выбор, а потому должен получить больший вес. Важным отличием объективных подходов является их реплицируемость, когда при одних и тех же данных все исследователи получают одинаковые веса, устраняя субъективное влияние. Основные представители: энтропийный метод (основывается на концепции информационной энтропии), метод CRITIC (Criteria Importance Through Inter-Criteria Correlation), метод Gini [9] (основывается на коэффициенте Джини, заимствованном из экономической теории для измерения неравномерности распределения).

Интегрированные подходы [10] стремятся объединить преимущества обоих подходов – субъективного и объективного. В таком подходе первоначально могут быть получены веса одним способом, а затем скорректированы другим, либо же производится прямая агрегация результатов двух и более методов. Комбинированные методы не имеют собственной уникальной формулы, они заимствуют черты исходных методов, составляющих смесь [11]. Зато их сильная сторона – более реалистичные и сбалансированные веса, одновременно отражающие и предпочтения экспертов, и структуру данных. Существует множество вариантов интеграции: от простого усреднения до сложных алгоритмов оптимизации [12–14].

В таблице 1 отражено сравнение методов и классов по сложности, универсальности и устойчивости к шуму данных.

Таким образом, имеющийся научно-методический аппарат оценки значимости критериев не позволяет достаточно точно, оперативно и объективно присвоить веса к каждому из критериев. В настоящее время [2, 3] имеются исследования, в которых производится частичная интеграция методов искусственного интеллекта в многокритериальное принятие решений, что открывает возможности перехода от субъективных оценок к объективно рассчитанным весам, основанным на данных.

В данной работе рассматривается подход, в котором машинное обучение (ML) используется для автоматического определения весовых коэффициентов критериев в интересах определения точного и объективного решения при работе системы ППР диспетчера ОКИ.

Данный метод позволит формировать веса из эмпирических данных о предпочтениях или результатах, устраняя субъективные предположения и повышая обоснованность многокритериального анализа. Использование ML в многокритериальном анализе ранее сталкивалось с трудностями, связанными с отсутствием обучающих данных достаточного объема. Для преодоления этой трудности в работе предложено использование генеративных больших языковых моделей, которые позволили получить необходимые выборки весов. Исследование направлено на сравнение классических аналитических методов определения весов критериев и ML-подходов, а также на проверку гипотезы о том, что ML-модели способны предсказывать веса критериев на основании особенностей распределения его оценок по множеству альтернатив, а также в характере его статистических связей с другими критериями, а также учитывать структуру экспертных данных.

Метод определения весов критериев

Запишем постановку задачи определения весовых коэффициентов критериев в многокритериальной модели оценки.

Пусть задано множество альтернатив:

$$A = \{A_1, A_2, \dots, A_M\},$$

оцениваемых по конечному набору критериев:

$$K = \{K_1, K_2, \dots, K_N\}.$$

Экспертные оценки представлены в виде матрицы:

$$X = \begin{pmatrix} x_{11} & x_{12} & x_{1N} \\ \vdots & \ddots & \vdots \\ x_{M1} & x_{M2} & x_{MN} \end{pmatrix},$$

Таблица 1

Сравнение методов

| Метод | Класс | Экспертное участие | Сложность | Универсальность | Устойчивость к шуму |
|------------------------------|-----------------|-------------------------------------|-----------|------------------------------------|---------------------------------|
| АНР (метод парных сравнений) | Субъективный | Высокое (требуется суждения ЛПР) | Средняя | Высокая (применим даже без данных) | Высокая (не зависит от данных) |
| BWM (best-worst) | Субъективный | Высокое | Низкая | Высокая | Высокая (не зависит от данных) |
| Энтропийный метод | Объективный | Нет | Низкая | Ограниченная (нужны данные) | Низкая (чувствителен к данным) |
| CRITIC | Объективный | Нет | Средняя | Ограниченная | Средняя |
| Gini | Объективный | Нет | Средняя | Ограниченная | Средняя |
| MEREC | Объективный | Нет | Высокая | Ограниченная | Высокая (стабильные результаты) |
| CILOS | Объективный | Нет | Высокая | Ограниченная | Средняя |
| IDOCRIW | Интегрированный | Нет (объединяет объективные методы) | Средняя | Ограниченная | Средняя |

где m, n – значение m -й альтернативы по n -му критерию.

Требуется определить вектор весовых коэффициентов:

$$w = (w_1, w_2, \dots, w_N),$$

удовлетворяющих условиям неотрицательности и нормировки:

$$w_n \geq 0, \sum_{n=1}^N w_n = 1.$$

Описываемая ниже методика сопоставляет совокупность взаимодополняющих статистических характеристик, что существенно отличает ее от классических методик. Методика позволяет представить критерии в виде многомерного признакового пространства и формализовать задачу назначения весовых коэффициентов как задачу регрессионного анализа.

Для каждого критерия формируется многомерный вектор признаков на основе статистических характеристик его оценок по всем альтернативам. Используемые признаки включают показатели центральной тенденции, вариативности, формы распределения, корреляционных связей с другими критериями, а также информационной насыщенности.

Для каждого критерия K_n рассматривается вектор его оценок на основании статистик таблицы 2.

Таким образом, каждому критерию K_n сопоставляется вектор признаков:

$$z_n = (\mu_n, \sigma_n, x_n^{\min}, x_n^{\max}, R_n, CV, \tilde{x}_n, Q_{0,25n}, Q_{0,75n}, IQR_n, Skew_n, \tilde{\rho}_n, \rho_n^{\max}, H_n).$$

В методике весовые коэффициенты рассматриваются как линейная функция признаков:

$$w_n = z_n^T \beta + \xi_n,$$

где β – вектор параметров модели, ξ_n – случайная ошибка.

Для оценки параметров используется Lasso-регрессия, решение которой определяется задачей оптимизации:

$$\beta = \arg \min_{\beta} \sum_{n=1}^N (w_n - z_n^T \beta),$$

где P – размерность вектора признаков, λ – параметр регуляризации.

Полученные значения весов нормализуются:

$$w_n = \frac{\max(w_n, \epsilon)}{\sum_{k=1}^N \max(w_k, \epsilon)},$$

где ϵ – численный порог для нормализации. Схема методики представлена на рис. 1.

В результате применения предложенной методики каждому критерию многокритериальной модели сопоставляется количественно обоснованный весовой коэффициент, отражающий его относительную значимость при решении задачи многокритериальной оптимизации. Использование статистических характеристик распределения экспертных оценок позволяет учитывать не только средний уровень значений критериев, но и их вариативность, асимметрию, взаимосвязи с другими критериями, а также информационную насыщенность.

Стоит отметить, что обучение производится на уровне критериев, а не альтернатив, что принципиально отличает подход от классических MCDM-методов.

Полученные весовые коэффициенты обладают устойчивостью к шуму в исходных данных, формируются автоматически на основе объективных свойств данных, что обеспечивает воспроизводимость результатов и повышает надёжность итоговых оценок в условиях ограниченного объёма обучающей выборки.

Для получения оценок и альтернатив в данном подходе предлагается использовать LLM модель как источник альтернатив, оценок и «главного эксперта», который определяет истинные веса критериев. Для обучения LLM модели необходимо формировать данные специальным образом в интересах уменьшения числа ошибок.

Формирование данных

На первом этапе задаются параметры генерации: M (число альтернатив), N (число критериев), K (число экспертов), а также текстовые поля *domain* и *objective*. Дополнительно фиксируются параметры LLM-вызовов (модель и температура), что обеспечивает воспроизводимость условий генерации на уровне конфигурации.

Таким образом, формируются матрицы оценок x_{kij} по каждой паре (a_i, c_j) для каждого эксперта e_k , где $A = \{a_i\}_{i=1}^N$ – множество альтернатив, $C = \{c_j\}_{j=1}^M$ – множество критериев, $E = \{e_k\}_{k=1}^K$ – множество экспертов.

LLM генерирует списки альтернатив и критериев строго заданной мощности: $|A|=N$, $|C|=M$. Для устойчивости извлечения результатов используется ответ в виде JSON.

С помощью запроса и ключевых слов (промпта) формируется набор экспертов $|E|=K$, где каждый эксперт описывается атрибутами (идентификатор, роль, стаж, компетентность, стиль рассуждения), которые затем используются как условие при получении оценок. На практике это реализует контролируемую гетерогенность мнений в группе.

Далее для каждого эксперта e_k с помощью запроса к модели генерируется матрица оценок размерности

Таблица 2

Статистики для формирования признаков в модели назначения весовых коэффициентов

| Основные статистические характеристики | |
|--|---|
| Математическое ожидание | $\mu_n = \frac{1}{M} \sum_{m=1}^M x_{m,n}$ |
| Стандартное отклонение | $\sigma_n = \sqrt{\frac{1}{M} \sum_{m=1}^M x_{m,n}^2}$ |
| Минимум и максимум | $x_n^{\min} = \min_m x_{m,n}, x_n^{\max} = \max_m x_{m,n}$ |
| Размах | $R_n = x^{\max} - x^{\min}$ |
| Коэффициент вариации | $CV_n = \frac{\sigma_n}{ \mu_n + \varepsilon}$ |
| Квантильные характеристики | |
| Медиана | $x_n = median(x_n)$ |
| Первый и третий квартили | $Q_{0,25n}, Q_{0,75n}$ |
| Межквартильный размах | $IQR_n = Q_{0,75n} - Q_{0,25n}$ |
| Характеристики формы распределения | |
| Коэффициент асимметрии | $Skew_n = \frac{1}{M} \sum_{m=1}^M \left(\frac{x_{m,n} - \mu_n}{\sigma_n} \right)^3$ |
| Коэффициент эксцесса | $Kurt_n = \frac{1}{M} \sum_{m=1}^M \left(\frac{x_{m,n} - \mu_n}{\sigma} \right)^4 - 3$ |
| Корреляционные характеристики | |
| Средняя корреляция | $\rho_n = \frac{1}{N-1} \sum_{k \neq n} \rho_{n,k} $ |
| Максимальная корреляция | $\rho_n^{\max} = \max_{k \neq n} \rho_{n,k} $ |
| Энтропийная характеристика | |
| Энтропия критерия | $H_n = \frac{1}{\ln(M)} \sum_{m=1}^M \ln(\rho_{m,n})$ |

$N \times M$, где элементы x_{kj} лежат на ограниченной шкале $[0; 100]$. Генерация выполняется тем же механизмом JSON-схем, что снижает долю ошибочных ответов и упрощает парсинг. Далее результаты приводятся к фиксированному порядку альтернатив и индикаторов.

Отдельный промпт-запрос к модели формирует эталонный вектор весов w по списку критериев и контексту задачи. Веса нормируются, $\sum_j w_j = 1$, а для каждого веса сохраняется текстовое обоснование. Полученные данные используются для экспериментов по восстановлению/согласованию весов или для оценки качества ранжирования.

LLM в данном генераторе выступает не просто источником текста, а формальным участником процедуры назначения весов, то есть моделирует когнитивно и профессионально обусловленные решения группы экспертов при фиксированной постановке

задачи. Это достигается тем, что модель последовательно переводится в разные функциональные роли: сначала она синтезирует пространство выбора (альтернативы и критерии), затем порождает гетерогенную группу персон-экспертов и, наконец, от имени каждого такого эксперта производит численные оценки альтернатив по каждому критерию на общей шкале. Соответственно, LLM реализует сразу три уровня валидации содержательной правдоподобности:

- семантическую согласованность сущностей с контекстом *domain* и *objective*;
- правдоподобную вариативность мнений между экспертами за счёт различающихся профилей (роль, опыт, компетентность и стиль);
- численную определённость оценок, достаточную для последующей агрегации и сравнения методов группового многокритериального выбора.

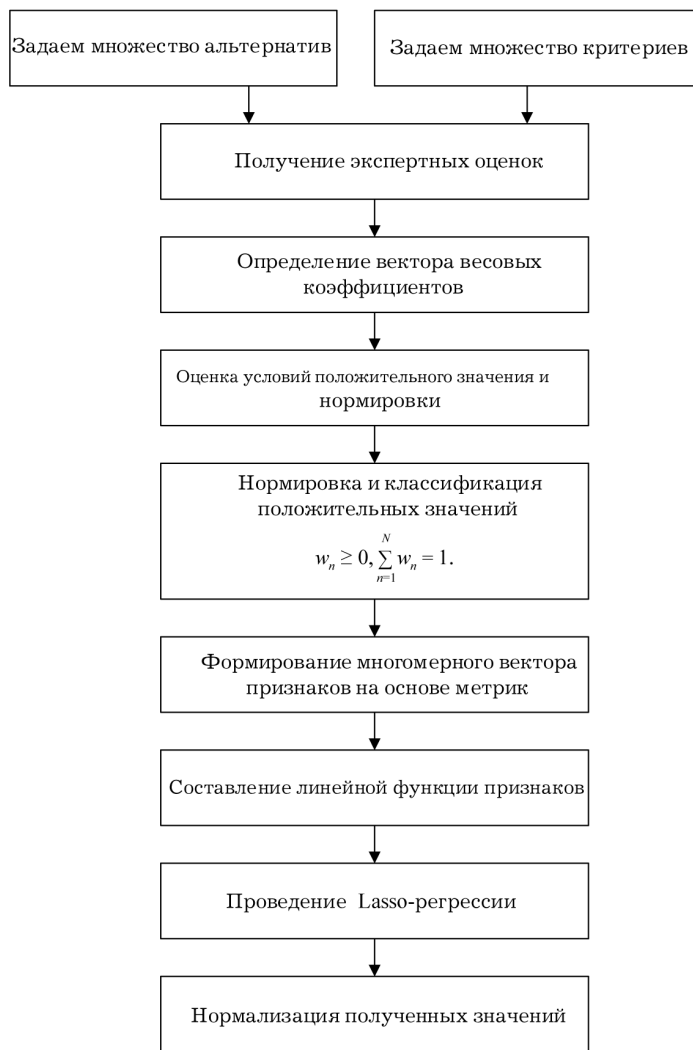


Рис. 1. Схема методики определения весов критериев

На уровне промптинга это выражено тем, что генерация альтернатив и индикаторов задаётся как отдельная стадия постановки данных.

Результаты

Для проведения эксперимента сгенерировано 25 задач по 4 областям с использованием модели gpt-4o-mini. Параметры генерации задач приведены на рис. 2.

Также сгенерированы эксперты, пример профиля эксперта на рис. 3.

Для агрегации весов использован метод с учетом компетентности эксперта:

$$w_j = \sum_{e=1}^k \frac{competence_e}{\sum_j competence} w_{e,j}.$$

Истинные веса критериев сгенерированы с помощью модели-критика.

Для оценки качества восстановления весов используется метрика MSE, которая измеряет, насколько точно метод восстанавливает веса.

Программный комплекс реализован на языке Python с использованием библиотек LangChain и openai и API openai для генерации Экспертов задач и альтернатив, а также sklearn для обучения моделей машинного обучения.

На схеме рис. 4 показана двухсервисная архитектура программного комплекса на Python. Сервис 1 отвечает

за генерацию исходных данных: через оркестратор запускается пайплайн, реализованный на библиотеке LangChain, который формирует промпты и вызывает OpenAI API для создания профилей экспертов, задач и альтернатив. Полученные результаты проходят этап валидации и нормализации (проверка формата ответа), после чего сохраняются и собираются в единый набор данных. Сервис 2 принимает этот набор данных и выполняет ML-часть: сначала данные преобразуются в признаки, далее в блоке обучение и оценка с использованием библиотеки scikit-learn обучаются модели, восстанавливающие истинные веса. Для прикладного использования может быть inference API. Завершает контур мониторинг качества, результаты которого могут использоваться как обратная связь для улучшения генерации и правил валидации в Сервисе 1.

Далее обучены 4 модели машинного обучения для определения весов (таблица 3).

На основании результата эксперимента делается вывод об эффективности модели Ridge для предсказания весов критериев.

Далее проведен эксперимент расчета весов различными известными методами (таблица 4).

Следующим шагом проведено сравнение лучшей модели с существующими аналитическими методами: методом усреднения и комбинированным методом оценки (таблица 5).

На основании результатов можно сделать вывод, что ML (Ridge) показывает лучшую точность в весах – на 30 % лучше, чем усреднение оценок, и на 57 % ниже

```
{
  "meta": {
    "n_tasks": 25,
    "model": "gpt-4o-mini",
    "temperature": 0.7,
    "domains_used": [
      "Выбор поставщика облачных услуг",
      "Выбор облачной DWH/BI платформы",
      "Выбор языка программирования для нового проекта",
      "Выбор CRM-системы"
    ]
  },
},
```

Рис. 2. Параметры для генерации задач и альтернатив

```
"/
"expert": {
  "id": "task_0002",
  "name": "Мария Смирнова",
  "role": "Бизнес-аналитик",
  "years_exp": 8,
  "competence": 0.9,
  "style": "Стратегический",
  "background": "Имеет опыт в выборе и внедрении CRM-систем для малых и средних предприятий, а также в анализе потребностей бизнеса."
},
"expert_scores": {
  "Salesforce": {
    "Стоимость внедрения": 70.0,
    "Функциональность": 90.0,
    "Удобство использования": 75.0,
    "Интеграция с другими системами": 85.0,
    "Поддержка и обучение": 80.0,
    "Масштабируемость": 80.0
  },
},
```

Рис. 3. Пример профиля эксперта

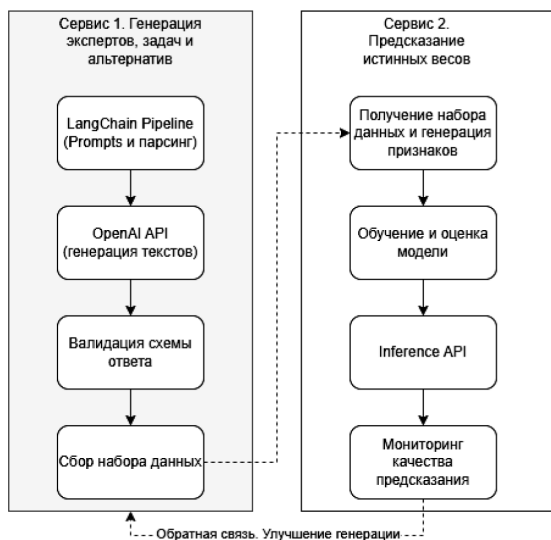


Рис. 4. Схема реализации программного комплекса

Таблица 3

Метрики определения весов с помощью ML-моделей

| Модель | MSE_cv | MSE_test |
|------------------|---------|----------|
| Ridge | 0.00780 | 0.00370 |
| Lasso | 0.00819 | 0.00405 |
| RandomForest | 0.00953 | 0.00384 |
| GradientBoosting | 0.01100 | 0.00457 |

Таблица 4

Усредненное качество каждого метода по всем экспертам

| Метод | MSE | MAE | MAPE | Spearman | $R a n_{MAE}$ | $R a n_{Spearman}$ |
|-------------|--------|--------|---------|----------|---------------|--------------------|
| Removal | 0,0047 | 0.0599 | 88,86 | 0,9714 | 0,1143 | 0,9714 |
| Angular | 0,0074 | 0,0681 | 78,05 | 0,9714 | 0,1143 | 0,9429 |
| Gini | 0,0077 | 0,0704 | 86,83 | 0,9571 | 0,1714 | 0,9571 |
| Dispersion | 0,0078 | 0,0706 | 87,02 | 0,9571 | 0,1714 | 0,9571 |
| STD | 0,0082 | 0,0731 | 88,18 | 0,9714 | 0,1143 | 0,9714 |
| Entropy | 0,0471 | 0,1854 | 481,03 | 0,9571 | 0,1143 | 0,9714 |
| Correlation | 1,1039 | 0,8427 | 2106,14 | -0,4429 | 1,8295 | -0,4429 |

Таблица 5

Метрики определения весов с помощью ML-моделей

| Метод | MSE | MAE | MAPE |
|-----------------|-------|-------|--------|
| ML (Ridge) | 0.004 | 0.056 | 103.64 |
| Усреднение | 0.013 | 0.089 | 259.52 |
| Комбинированный | 0.009 | 0.076 | 211.85 |

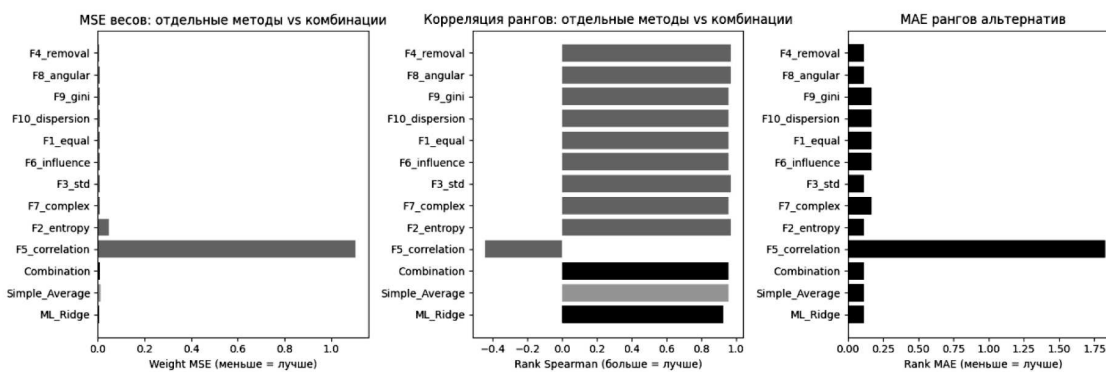


Рис. 5. Сравнение методов




Рис. 6. Пример профиля эксперта

по сравнению с комбинированным подходом. И данное различие статистически значимо ($p\text{-value}=0.0016$).

Также построен график для визуального сравнения всех методов.

Результаты (рис. 5, график 1) показывают, что использование отдельных аналитических критериев приводит к высокой ошибке восстановления весов. Наилучшее качество достигается при использовании ML-подхода, который интегрирует несколько статистических характеристик критериев одновременно. Даже если некоторые методы дают приемлемую корреляцию, их поведение нестабильно (рис. 5, график 2). Минимальное значение MAE рангов у ML-подхода (рис. 5, график 3) свидетельствует о его практическом преимуществе при выборе альтернатив, особенно в задачах топ- k отбора.

Дополнительно проведен эксперимент по влиянию размера выборки на точность определения весов моделью. Зависимость веса MSE от размера выборки показана на рис. 6.

График (рис. 6) демонстрирует, что ML-подход к определению весов критериев выигрывает от увеличения объема данных. Модель становится значительно точнее в определении самих весов (MSE снижается) и немного улучшает свою способность правильно ранжировать альтернативы (Rank Spearman растёт) по мере получения большего количества примеров от экспертов. На основании графика делается вывод о хорошей масштабируемости ML-моделей для решения задачи назначения весов.

Заключение

В работе предложен и экспериментально исследован подход к определению весов критериев в задачах многокритериальной поддержки принятия решений, основанный на использовании методов машинного обучения и генеративных языковых моделей. В отличие от методик, построенных на классических аналитических и экспертных методах, предложенная методика формализует задачу назначения весов как задачу регрессии, в которой каждый критерий описывается совокупностью статистических характеристик распределения его оценок по множеству альтернатив.

Проведённые эксперименты показали, что ML-подход, в частности модель Ridge-регрессии, обеспечивает более точное восстановление эталонных весов по сравнению с отдельными аналитическими и комбинированными методами, а также демонстрирует более устойчивое поведение при наличии шума в экспертных оценках. Кроме того, улучшение качества оценки весов приводит к более корректному итоговому ранжированию альтернатив, что подтверждает практическую значимость подхода для задач выбора и приоритизации.

Использование генеративных языковых моделей позволило решить проблему недостатка обучающих

данных и обеспечить воспроизводимую экспериментальную среду для сравнения методов. При этом сам предложенный подход не зависит от генеративных моделей по своей природе и может быть применён к реальным экспертным данным.

Полученные результаты подтверждают целесообразность применения методов машинного обучения для автоматизированного и объективного определения весов критериев. Дальнейшим направлением работы может стать расширение признакового пространства, использование нелинейных моделей и валидацией подхода на прикладных задачах поддержки принятия решений.

Литература

1. Онтологические модели для систем управления электро-снабжением олимпийских объектов в Сочи / Е.Н. Мельник, А.Ю. Бадалов, Б.Я. Шведин [и др.] // Онтология проектирования. – 2014. – № 1 (11). – URL : <https://cyberleninka.ru/article/n/ontologicheskie-modeli-dlya-sistem-upravleniya-elektrosnabzheniem-olimpiyskih-obektov-v-sochi> (дата обращения: 05.02.2026).
2. Интеллектуальная поддержка экипажа на основе доверительной модели замкнутой эргатической системы «Самолёт-Лётчик» / В.Н. Евдокименко, Р.В. Ким, М.Н. Красильщиков, Г.Г. Себряков. – Москва : Физматлит, 2019. – 192 с.
3. Post-storm repair crew dispatch for distribution grid restoration using stochastic Monte Carlo tree search and deep neural networks / H. Shuai, F. Li, S. Buxin [et al.] // International Journal of Electrical Power & Energy Systems. – 2023. – Vol. 144. – P. 108477.
4. Саати, Т.Л. Принятие решений. Метод анализа иерархий / Т.Л. Саати. – Москва : Радио и связь, 1993. – 278 с.
5. Боев, С.Ф. Методика построения диалоговой системы в средствах автоматизации управления на основе формализованной концептуальной информационной модели автоматизированных рабочих мест / С.Ф. Боев, А.В. Зюзин, П.А. Морозов // Информация и Космос. – 2021. – № 4. – С. 46–54.
6. Концептуальные основы построения интеллектуальной системы управления чрезвычайными ситуациями / С.П. Присяжнюк, Д.Ф. Ткачев, Д.И. Комашинский, В.И. Татаринцов // Информация и Космос. – 2025. – № 2. – С. 50–58.
7. Saaty, T.L. Decision making with the analytic hierarchy process / T.L. Saaty // International Journal of Services Sciences. – 2008. – Vol. 1, No. 1. – P. 83–98.
8. Cancio, I. AHP, a Reliable Method for Quality Decision Making: A Case Study in Business / I. Cancio, D. Kruja, T. Iancu // Sustainability. – 2021. – Vol. 13, No. 24. – P. 13932.
9. Determination of Objective Weights Using a New Method Based on the Removal Effects of Criteria (MEREC) / M.Keshavarz-Ghorabae, M. Amiri, E.K. Zavadskas [et al.] // Symmetry. – 2021. – Vol. 13, No. 4. – P. 525.
10. Mukhametzyanov, I. Specific character of objective methods for determining weights of criteria in MCDM problems: Entropy, CRITIC and SD / I. Mukhametzyanov // Decision

Making: Applications in Management and Engineering. – 2021. – Vol. 4, No. 2. – P. 76–105.

11. Odu, G. Weighting methods for multi-criteria decision making technique / G. Odu // Journal of Applied Sciences and Environmental Management. – 2019. – Vol. 23, No. 8. – P. 1449.

12. Wang, Z. Multi-Criteria Decision Making in Chemical and Process Engineering: Methods, Progress, and Potential / Z. Wang, S.R. Nabavi, G.P. Rangaiah // Processes. – 2024. – Vol. 12, No. 11. – P. 2532.

13. A Hybrid Multi-Criteria-Decision-Making Aggregation Method and Geographic Information System for Selecting Optimal Solar Power Plants in Iran / J.H. Dahooie, A.H. Kashan, Z.S. Naeini [et al.] // Energies. – 2022. – Vol. 15, No. 8. – P. 2801.

14. Chetverushkin, B.N. Graph Condensation for Large Factor Models / B.N. Chetverushkin, V.A. Sudakov, Yu.P. Titov // Doklady Rossijskoj Akademii Nauk. Matematika, Informatika, Processy Upravleniya. – 2024. – Vol. 517, No. 1. – P. 66–73.

15. Соловьев, Д.С. Метод объективизации значений весовых коэффициентов для принятия решений в многокритериальных задачах / Д.С. Соловьев // Научно-технический вестник информационных технологий механики и оптики. – 2023. – Т. 23, № 1. – С. 161–168.

16. Машунин, К.Ю. Векторная оптимизация с равнозначными и приоритетными критериями / К.Ю. Машунин, Ю.К. Машунин // Известия РАН. Теория и системы управления. – 2017. – № 6. – С. 80–89.

17. Mandilm, A.D.A. Opinion Weight Criteria Method (OWCM): A New Method for Weighting Criteria With Zero Inconsistency / A.D.A. Mandil, M.M. Salih, Y.R. Muhsen // IEEE Access. – 2024. – Vol. 12. – P. 5605–5616.