

# ОБЗОР СОВРЕМЕННЫХ ТЕХНИК АНСАМБЛИРОВАНИЯ В МАШИННОМ ОБУЧЕНИИ ДЛЯ ПОВЫШЕНИЯ КАЧЕСТВА КЛАССИФИКАЦИИ

## REVIEW ON MODERN ENSEMBLE TECHNIQUES IN MACHINE LEARNING TO IMPROVE THE QUALITY OF CLASSIFICATION

**E. Kubrakova**

*Summary.* The article examines the features of using ensemble techniques in machine learning to improve the quality of classification. The main scientific and practical studies on software implementation, construction of models and algorithms of ensembling for use in various fields are highlighted.

*Relevance.* Data mining, used in machine learning, often faces various tasks, among which one of the key ones is the implementation of classification. It involves dividing the data into certain categories according to predefined classes. The ensemble method usually uses a combination of several classifiers. This is done to improve the results compared to the output data provided by each classifier individually. The key idea is that by combining responses in a variety of ways, individual errors can be eliminated, thereby achieving a higher overall quality of the solution within the ensemble.

*The purpose* of the article is to highlight the main aspects of the application of ensemble techniques in machine learning to improve the quality of classification.

*The result* of the research is the study of scientific, theoretical, practical provisions, the identification of the main approaches to the construction of ensembles of algorithms. In conclusion, the author's conclusions are given.

*Keywords:* ensemble, algorithm, classification task, boosting, bagging, stacking.

**Кубракова Екатерина Александровна**

Аспирант, Московский физико-технический институт  
(Национальный исследовательский университет)  
ekubrakova@ya.ru

*Аннотация.* В статье исследованы особенности использования техник ансамблирования в машинном обучении для повышения качества классификации. Выделены основные научно-практические исследования по программной реализации, построению моделей и алгоритмов ансамблирования для использования в различных сферах.

*Актуальность.* Интеллектуальный анализ данных, применяемый в машинном обучении, часто сталкивается с различными задачами, среди которых одной из ключевых является выполнение классификации. Она подразумевает разделение данных на определенные категории в соответствии с заранее установленными классами. В методе ансамблирования обычно применяют комбинацию нескольких классификаторов. Это делается для того, чтобы улучшить результаты по сравнению с выходными данными, которые дает каждый классификатор по отдельности. Ключевая идея заключается в том, что путем разнообразного объединения ответов можно устранить индивидуальные ошибки, тем самым достигая более высокого общего качества решения в рамках ансамбля.

*Целью* статьи является выделение основных аспектов применения техник ансамблирования в машинном обучении для повышения качества классификации.

*Результатом* исследования является изучение научно-теоретических, практических положений, выделение основных подходов к построению ансамблей алгоритмов. В заключение даны авторские выводы.

*Ключевые слова:* ансамбль, алгоритм, классификация, задача, бустинг, бэггинг, стэкинг.

### Введение

В современной практике часто используется методика ансамблирования (далее МА) алгоритмов машинного обучения (далее МО) для решения различных задач. Этот подход включает в себя объединение нескольких простых классификаторов (далее ПК), также называемых базовыми, для улучшения качества классификационных решений за счет взаимной компенсации их ошибок. Различные способы комбинирования ПК позволяют достичь более высокой точности в решении задач классификации (далее ЗК) [1, 2].

### Актуальность

Эффективность классификации данных может значительно улучшиться с использованием МА в МО. Такой подход включает в себя комбинирование различных ПК для того, чтобы минимизировать их отдельные ошибки и усилить общую эффективность рабочей системы. Каждая МА имеет свои уникальные сильные и слабые стороны, но в целом, системы, построенные на ансамблях, часто демонстрируют лучшие результаты по сравнению с использованием ПК, особенно в плане точности и надежности. Алгоритмы МО, объединенные в ансамбли, используются во многих сферах, включая анализ финан-

сов, биоинформатику, обработку естественного языка и распознавание образов, благодаря своей высокой надежности [3, 4].

Целью статьи является обзор основных современных подходов к созданию ансамблей в МО и выделение важных аспектов их применения для повышения качества классификации.

Основными задачами исследования являются:

1. Выделение особенностей построения процесса ансамблирования с точки зрения различных авторов.
2. Выделение подходов к построению ансамблей алгоритмов.
3. Обоснование значимости применения МА по сравнению с использованием ПК.

### Материалы и методы исследования

Основаны на анализе научно-практических данных, обобщении, синтезе мнений и показателей, описании математического аппарата алгоритмов МО, графической интерпретации результатов.

### Результаты исследования

В конце 70-х Ю.И. Журавлёв предложил алгебраический подход (далее АП) для решения задач распознавания и ЗК. Основная идея заключалась в том, что алгоритм, который не ошибается при проверке выборки, должен быть разработан как алгебраическая формула, использующая эвристические последовательности. Для операторов распознавания были определены такие операции, как сложение, умножение на константу и умножение, аналогичное матричному, где каждое действие выполнялось поэлементно. Эти математические операции, применяемые при установленных правилах решения, влияли на результаты работы алгоритмов вычисления оценок (далее АВО). В теории распознавания было установлено, что можно создавать эффективные АВО, используя строго АП, что стало ключевым достижением в области поиска возможностей распознавания и классификации. В частности, для модели с кусочно-линейными функциями было показано, что существует необходимость формулировки и четкого описания действенного полиномиального алгоритма, который оперирует на основе неидеальных АВО. Множество всех полиномов степени не выше  $k$  над алгоритмами некоторой модели было названо алгебраическим замыканием  $k$ -й степени этой модели (при  $k=1$  — линейным замыканием) [5, 6].

В своих исследованиях, К.В. Рудаков разработал теорию, охватывающую локальные и универсальные ограничения, используя АП. Это позволило ему сформировать язык для анализа и описания задач, связанных

с трансформацией информации, опираясь на начальные «слабые» позиции [7].

МА или английский термин «ensemble learning» представляет собой методику создания АВО, включающего в себя множество алгоритмов МО. Такой составной АВО обозначается как ансамбль или Multiple Classifier System. В случаях, когда речь идет о классификации, самый базовый тип ансамбля — это так называемый комитет большинства (рисунок 1).




Рис. 1. Графическая интерпретация вероятности ошибок базового типа ансамбля [8]

Формализованное описание построения классифицирующих АВО при помощи МА представлено в работах некоторых авторов, которые занимались изучением конечного множества системных состояний  $\{z_1, \dots, z_l\} \in (1)$ . Было выявлено, что они зависимы от внутренних и внешних модификаций, что подвергает их трансформации в дискретные моменты [9, 10, 11].

Клюева И.А. отмечает, что в области анализа данных успешность применения МА обусловлена рядом ключевых аспектов.

1. Процесс решения ЗК происходит за счет создания обширного числа гипотез. Целью является поиск «наилучшего» из возможных вариантов, что позволяет более точно описывать взаимосвязи в данных.
2. Классификационные АВО часто пользуются методикой нахождения локальных экстремумов, когда цель поиска — найти экстремум функции. Вариативность в выборках данных, использованных для построения ПК в ансамблях моделей, способствует увеличению шансов на обнаружение глобально оптимальных решений, поскольку исследование проводится с различных стартовых позиций [12, с.77–78].

Для того чтобы улучшить объективность при принятии классификационных решений, важно достичь баланса случайных выводов различных ПК внутри ансамбля. Эффективность применения МА  $\frac{b_w}{Z} \rightarrow V(2)$  прямо коррелирует с разнообразием и качеством ПК, включенных в ансамбль.

Козлов Д.А. в своем исследовании [13] предлагает применение АВО для МА, с несколькими из них, для МО




Рис. 2. Результат исследования Козлова Д.А. Козлов Д.А. [13]

с подкреплением. Было практически доказано, что данный способ является более эффективным для работы, чем использование каждого алгоритма в отдельности. В области МО обучение с подкреплением представляет собой одно из наиболее перспективных направлений. Однако, столкнувшись со сложными ЗК, которые включают множество подзадач, возникает проблема их обобщения. Для решения данной проблемы предлагается использовать МА различных алгоритмов, что может улучшить обобщение и эффективность работы. В частности, результат ансамбля определяется АВО, выбранным с помощью DQN. При этом использование разнообразных АВО в ансамбле и в разном количестве открывает новые возможности для оптимизации процесса МО (рисунок 2).

Воронцов К.В., Кашницкий Ю.С., Игнатов Д.И. и др. рассматривали подходы к построению ансамблей алгоритмов, наиболее популярными из которых являются методы бэггинга (bagging, bootstrap aggregating), бустинга (boosting) и стекинга (stacked generalization, stacking) [14, 15, 16, 17].

#### Бустинг в ЗК

Метод бустинга (далее МБ) представляет собой способ, где АВО объединяются в ансамбль пошагово, причём каждый новый интегрируется для оптимизации ошибок, выявленных на данной стадии, используя так называемый «жадный» принцип. Среди широко применяемых способов МБ выделяются AdaBoost, или адаптивный бустинг, и градиентный бустинг. Особенно высокую эффективность показывает XGBoost, который базируется на использовании решающих деревьев в рамках градиентной МБ. Множество исследований показали, что МБ, применяемый к решающим деревьям, является чрезвычайно эффективным для улучшения точности классификации. Примечательно, что с увеличением числа эле-

ментов в композиции, ошибка на независимой тестовой выборке продолжала снижаться, достигая в некоторых случаях почти нулевого уровня. Даже после того, как обучающая выборка была классифицирована без ошибок, качество результатов на тестовой выборке продолжало совершенствоваться [18–21].

#### Бэггинг в ЗК

В способе бэггинга (далее СБ) используются однородные базовые АВО для создания ансамбля. Они обучаются параллельно, каждый на своей случайной подвыборке, которая формируется с повторениями из исходной обучающей выборки. Такой подход является частью метода бутстрапа. Концепция бэггинга также присутствует в RF-алгоритме [22].

Эта техника включает в себя создание нескольких ПК, каждый из которых обучен на уникальных частях набора данных. Все они следуют одному и тому же АВО, но применяют его к разным подмножествам сведений. Чтобы сформировать окончательный прогноз, результаты от каждого классификатора собираются вместе, используя методы среднего значения или голосования [23].

Вопрос о составе ансамбля классификаторов при применении СБ выделяется как чрезвычайно сложный. Исследования часто фокусируются на применении классификаторов, которые не обладают высокой точностью. Рекомендации по созданию обучающих подвыборок советуют избегать стабильных вариантов, чтобы повысить «различность» между классификаторами. Также рассматривается возможность сочетания точных и относительно слабых классифицирующих АВО в рамках одного ансамбля, хотя конкретные правила для формирования операций вычисления остаются в большинстве случаев неопределёнными [24].

В ряде статей рассмотрены различные подходы к комбинированию алгоритмов в ансамблях, среди которых присутствуют методы с различающимися качественными характеристиками [25–28]. Особое внимание уделено техникам стекинга, блендинга и многоуровневого стекинга, показывающим высокую эффективность [30–32].

Метод стекинга, известный также как стековое обобщение, предполагает создание ансамбля из нескольких традиционных моделей для улучшения прогнозных способностей через обучение мета-алгоритма. Этот подход часто используется в ситуациях, когда не ясно, какая технология МО лучше всего справится с данными, особенно если они содержат шум или пропуски, что обычно встречается в прикладных задачах. В основе стекинга лежит идея совместного использования нескольких отдельных схем для создания более мощного и надежного предсказательного инструмента.

Стекинг при этом предполагает применение мета-алгоритма, который обучается на основе результатов различных базовых АВО, используемых как метахарактеристики. При этом ансамбли, обладающие большей гибкостью благодаря своему разнообразию параметров, часто превосходят одиночные АВО. Особенно эффективными они оказываются, когда ПК отличаются друг от друга, что улучшает точность и результаты МА. Одним из недостатков МА является то, что они требуют больше вычислительных ресурсов для создания решения по сравнению с базовыми АВО [33, 34, 35].

Модель реализации методики стекинг представлен на рисунке 3 (рисунок 3).

В методе блендинга, который является частью техники стекинга, используется только одно разделение обучающей выборки на части. На первом сегменте данных происходит обучение базовых ЗК. После этого они тестируются на втором сегменте и на отдельной тестовой выборке, где их предсказания становятся новыми мета-атрибутами. Используя полученные последователь-

ности со второй части обучающей выборки, создается метаклассификатор. При создании мета-классификатора используются элементы из тренировочного набора данных [37, 38]. Хотя блендинг и имеет преимущества в виде низкой вычислительной нагрузки и малого риска переобучения, к его недостаткам относятся сложности в настройке параметров разбиения выборки и невозможность использовать все данные эффективно.

Клюева И.А. предлагает использовать МА, такие как МБ и СБ, при разработке основных классификаторов для стекинга. Эти АВО отличаются друг от друга по своему подходу к систематике сведений и предоставляют основу для создания разнообразных типологий МО [11].

Среди ключевых преимуществ новых подходов к многоклассовой классификации по сравнению с существующими схемами автор выделяет несколько аспектов:

- Применение нечеткой логики для оценки принадлежности объектов к определенным классам в процессе вычисления метахарактеристик;
- Использование кросс-валидации для оценивания эффективности ПК;
- В отличие от метода стекинга, в этих новых методах для оценки метахарактеристик тестовых объектов применяется схема усреднения ответов ПК, которые были обучены на аналогичном объеме данных, как и для создания метахарактеристик обучающей выборки.

Разработанные методы, в отличие от блендинга, позволяют максимально эффективно задействовать всю обучающую выборку в процессе формирования метаклассификатора. В момент обучения метаклассификатора применяются не только исходные характеристики, но и метахарактеристики, которые формируются на основе данных, полученных от ПК.

**Обсуждение**

В области МО основная задача состоит в разработке оптимальной модели, способной точно прогнозировать



Рис. 3. Модель реализации методики стекинг



требуемые исходы. Внедрение МА предлагает альтернативный подход, где вместо полагания на одну, используется серия моделей. Затем происходит их интеграция, при помощи чего создается усовершенствованная конечная схема, которая является результатом усреднения предсказаний отдельных значений.

Представленные в обзоре исследования практически обосновывают, что ансамбль алгоритмов демонстрирует большую точность по сравнению с отдельными классификаторами, в особенности при небольших размерах обучающей выборки.

Исследования показывают, что новые методы и АВО представляют значительный интерес для применения в области бинарной и многоклассовой классификации. Это позволяет успешно справляться даже со сложными типами операций, такими как несбалансированное распределение классов в данных и необходимость эффективной настройки параметров в короткие сроки.

Эксперименты с использованием техник ансамблирования в решении задачи классификации сентимента новостных заголовков на русском языке [39] выявили

высокую эффективность применения МА даже по сравнению с нейросетевыми решениями в условиях ограниченных и несбалансированных наборов данных, что делает использование данной техники целесообразным и перспективным для решения разнообразных ЗК.

#### Заключение

Современные алгоритмы находят широкое применение в различных сферах, актуальных для сегодняшнего анализа данных. Они используются для оценки кредитоспособности, идентификации фальсификаций в транзакциях, прогнозирования ухода клиентов, а также в медицинской диагностике. Кроме того, эти технологии эффективны при фильтрации спама, классификации документов и других задачах.

Таким образом, внедрение МА и адаптация существующих АВО бинарной классификации для работы с ЗК, где необходимо различать несколько классов, а также использование техник кластеризации, представляют собой перспективные направления для дальнейших исследований.

#### ЛИТЕРАТУРА

1. Кашницкий Ю. История развития ансамблевых методов классификации в машинном обучении [Электронный ресурс] / Ю. Кашницкий // Elsevier B.V. 2015. Режим доступа: <https://doi.org/10.13140/RG.2.1.3933.2007>.
2. Michael Kearns, V. Umesh Vazirani. An Introduction to Computational Learning Theory, MA : The MIT Press, 1994.
3. Костров Б.В. Ансамблевые методы в задаче многоклассовой SVM-классификации / Б.В. Костров, А.И. Баранчиков, И.А. Ключева // XXI век: итоги прошлого и проблемы настоящего плюс. 2021, Т. 10, № 2(54), С. 105–108. — DOI 10.46548/21vek-2021-1054-0019.
4. Zelenchuk N.A., and Alsova O.K. A software implementation and research of ensemble algorithms for solving the different types of data classification problem, International Multi-Conference on Engineering, Computer and Information Sciences (SIBIRCON–2022): proc., Novosibirsk-Yekaterinburg. 2022, 11–13 Nov., IEEE, pp. 1610–1613.
5. Журавлев Ю.И., Об алгебраическом подходе к решению задач распознавания или классификации. Проблемы кибернетики. М.: Наука, 1978. Вып.33. С.5–68.
6. Журавлев Ю.И. Корректные алгоритмы над множествами не корректных (эвристических) алгоритмов. I. // Кибернетика. 1977, N4, С. 5–17, II. Кибернетика, N6, 1977, III. // Кибернетика. 1978. N2. С. 35–43.
7. Рудаков К.В. Об алгебраической теории универсальных и локальных ограничений для задач классификации // Распознавание, классификация, прогноз: Матем. методы и их применение. М.: Наука, 1988. Вып.1, С.176–200.
8. Ансамбли в машинном обучении // URL: <https://alexanderdyakonov.wordpress.com/2019/04/19/more-6535> (дата обращения: 13.05.2024).
9. Семенов В.В., Лебедев И.С., Сухопаров М.Е. Идентификация состояния отдельных элементов киберфизических систем на основе внешних поведенческих характеристик // Прикладная информатика. 2018, Т. 13, № 5(77), С. 72–83.
10. Сухопаров М.Е., Лебедев И.С. Идентификация состояния информационной безопасности устройств интернета вещей в информационно-телекоммуникационных системах // Системы управления, связи и безопасности. 2020, № 3. С. 252–268. doi: 10.24411/2410–9916-2020-10310.
11. Sukhoparov M.E., Lebedev I.S., Garanin A.V. Application of classifier sequences in the task of state analysis of Internet of Things devices // Informatics, telecommunications, and Management = Computing, Telecommunications and Control. 2020, Vol. 13, No. 3, pp. 44–54. doi: 10.18721/JCSTCS.13304
12. Ключева И.А. МЕТОДЫ И АЛГОРИТМЫ АНСАМБЛИРОВАНИЯ И ПОИСКА ЗНАЧЕНИЙ ПАРАМЕТРОВ КЛАССИФИКАТОРОВ: дис. ... канд. тех. наук: 05.13.17. Рязань, 2021, 173.
13. Метод ансамблирования алгоритмов обучения с подкреплением на основе иерархичности / Д.А. Козлов // Информационные технологии и нанотехнологии (ИТНТ-2023): сб. тр. по материалам IX Междунар. конф. и молодеж. шк. (г. Самара, 17–23 апр. 2023 г.): в 6 т. / М-во науки и высш. образования Рос. Федерации, Самар. нац. исслед. ун-т им. С.П. Королева (Самар. ун-т), Ин-т систем обраб. изобр. РАН — Фил. Федер. науч.-исслед. центра «Кристаллография и фотоника» Рос. акад. наук. — Самара: Изд-во Самар. ун-та, 2023Т. 4: Искусственный интеллект / под. ред. А.В. Никонорова. 2023, С. 040602.
14. Кашницкий Ю.С. Ансамблевый метод машинного обучения, основанный на рекомендации классификаторов / Ю.С. Кашницкий, Д.И. Игнатов // Интеллектуальные системы. Теория и приложения. 2015, Т. 19, № 4, С. 1–32.

15. Воронцов К.В. Комбинаторный подход к оценке качества обучаемых алгоритмов / К.В. Воронцов // Математические вопросы кибернетики / Под ред. О.Б. Лупанов. — М.: Физматлит. 2004, Т. 13, С. 5–36.
16. Erfani S.M. High-dimensional and large-scale anomaly detection using a linear one-class SVM with deep learning / S.M. Erfani, S. Rajasegarar, S. Karunasekera, C. Leckie // Pattern Recognition. 2016, Vol. 58, P.121–134.
17. Huang P.X. Individual feature selection in each One-versus-One classifier improves multi-class SVM performance / P.X. Huang, R.B. Fisher // Reference Source. 2014, P. 98–103.
18. Freund Y., Schapire R.E. Experiments with a new boosting algorithm // International Conference on Machine Learning. 1996, Pp. 148–156. <http://citeseer.ist.psu.edu/freund96experiments.html>.
19. Зинин С.Н. Использование алгоритмов бустинга в задачах классификации разнородных ДАННЫХ / С.Н. Зинин // Решетневские чтения. 2010, Т. 2, С. 495.
20. Чорный Д.А. Сравнительный анализ алгоритмов градиентного бустинга для задач классификации / Д.А. Чорный // Обработка информации и математическое моделирование: Материалы Российской научно-технической конференции, Новосибирск, 26–27 апреля 2017 года. Новосибирск: Сибирский государственный университет телекоммуникаций и информатики. 2017, С. 208–215.
21. Boosting the margin: a new explanation for the effectiveness of voting methods / R.E. Schapire, Y. Freund, W.S. Lee, P. Bartlett // Annals of Statistics. 1998, Vol. 26, no. 5, Pp. 1651–1686. <http://citeseer.ist.psu.edu/article/schapire98boosting.html>.
22. Гушин А.Е. Методы ансамблирования обучающихся алгоритмов [Электронный ресурс]. — Режим доступа: <http://www.machinelearning.ru/wiki/images/5/56/Guschin2015Stacking.pdf> (дата обращения 07.11.2020).
23. Синяев И.Ф. Исследование bagging подхода при построении ансамбля моделей для повышения точности классификации / И.Ф. Синяев, О.В. Шестернева // Актуальные проблемы авиации и космонавтики. 2014, Т. 1, № 10, С. 300.
24. Воронцов К.В. Лекции по алгоритмическим композициям [Электронный ресурс]. URL: <http://www.machinelearning.ru/wiki/images/0/0d/Voron-ML-Compositions.pdf> (дата обращения: 03.12.2020).
25. Zhou Z.-H. Ensemble Methods: Foundations and Algorithms. New York: CRC Press, 2012. 222 p.
26. Yu Y., Zhou Z.-H., Ting K.M. Cocktail ensemble for regression // Proc. 7th IEEE International Conference on Data Mining (ICDM). 2007, P. 721–726. doi: 10.1109/ICDM.2007.60
27. Zhou Z.-H., Feng J. Deep Forest // National Science Review. 2019. V. 6. N 1. P. 74–86. doi: 10.1093/nsr/nwy108.
28. Pedersen T.A simple approach to building ensembles of naive bayesian classifiers for word sense disambiguation // NAACL 2000: Proc. of the 1st North American chapter of the Association for Computational Linguistics Conference. 2000, P. 63–69.
29. Erfani S.M. High-dimensional and large-scale anomaly detection using a linear one-class SVM with deep learning / S.M. Erfani, S. Rajasegarar, S. Karunasekera, C. Leckie // Pattern Recognition. 2016, Vol. 58, P.121–134.
30. Полякова А.С.: Коллективные методы принятия решения на основе нечеткой логики, 2019 г. Красноярск.
31. Евсеева С.А. Исследование эффективности мета-алгоритмов, сформированных методом стекинга в задачах классификации / С.А. Евсеева, Д.В. Болдырев, Л.В. Липинский // Решетневские чтения : Материалы XXIV Международной научно-практической конференции, посвященной памяти генерального конструктора ракетно-космических систем академика М.Ф. Решетнева: в 2 частях, Красноярск, 10–13 ноября 2020 года. Том Часть 2. — Красноярск: Федеральное государственное бюджетное образовательное учреждение высшего образования «Сибирский государственный университет науки и технологий имени академика М.Ф. Решетнева», 2020, С. 169–171.
32. Fomin V., Duke V., Aleksandrov I. The use of machine learning methods for the determination of the fuel consumption of a gas turbine frigate // Marine intellectual technology. 2019. Vol. 1 (43). Pp. 156–160.
33. Kaftannikov I.L., Parasich A.V. Problems of training set's formation in machine learning tasks. Bulletin of the South Ural State University. Series Computer Technology, Automatic Control, Radio Electronics, 2016, vol. 16, no. 3, pp. 15–24. doi: 10.14529/ctcr160302
34. Klyueva I. Development of the SVM classifier by means of the hybrid versions of the particle swarm optimization algorithm based on the GRID SEARCH / L. Demidova, I. Klyueva // Computer modelling and new technologies. 2017, P. 56–63.
35. Klyueva I. Hybrid approach to improving the results of the SVM classification using the random forest algorithm / L. Demidova, I. Klyueva, A. Pylkin // Procedia Computer Science 2019, Vol. 150, P. 455–461.
36. Klyueva I. Improving Quality of the Multiclass SVM Classification Based on the Feature Engineering / I. Klyueva // 1st International Conference on Control Systems, Mathematical Modelling, Automation and Energy Efficiency (SUMMA— 2019). Lipetsk, 2019. P. 491–494.
37. Дьяконов А.Г. Стекинг (Stacking) и блендинг (Blending) [Электронный ресурс]. — Режим доступа: <https://dyakonov.org/2017/03/> (дата обращения 08.11.2023).
38. Ключева И.А. Ансамблевые методы в задаче многоклассовой SVM-классификации / Б.В. Костров, А.И. Баранчиков, И.А. Ключева // XXI век: итоги прошлого и проблемы настоящего плюс. 2021, Т. 10, № 2 (54), С. 105–108.
39. Кубракова Е.А. Классификатор новостных заголовков. // [Электронный ресурс]. — Режим доступа: [https://github.com/eakubrakova/Financial\\_news\\_classification](https://github.com/eakubrakova/Financial_news_classification) (дата обращения 10.07.2024).