


МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ РОССИЙСКОЙ ФЕДЕРАЦИИ
НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ УНИВЕРСИТЕТ ИТМО

известия студенческой науки



Выпуск 1

Том 1

Текстовое электронное издание

Санкт-Петербург
2025

МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ РОССИЙСКОЙ ФЕДЕРАЦИИ
НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ УНИВЕРСИТЕТ ИТМО

Известия студенческой науки

Сборник научных трудов

Выпуск 1. Том 1

Текстовое электронное издание



Санкт-Петербург
2025

УДК 004, 063, 065, 504

ББК 20, 32, 40

Известия студенческой науки. Выпуск 1. Том 1. Текстовое электронное издание (2235 Мб). СПб.: Университет ИТМО. 2025. 44 с.

Издание содержит результаты результатов научно-исследовательской деятельности обучающихся вузов и молодых ученых.

Мероприятие проводится в рамках реализации гранта в форме субсидий из федерального бюджета образовательным организациям высшего образования на реализацию мероприятий, направленных на поддержку студенческих научных сообществ (Соглашение № 075-15-2025-536 от 30 мая 2025 г.).

Под общей редакцией кандидата физико-математических наук, заместителя начальника департамента научных исследований и разработок Белашенкова Н.Р.

ISBN 978-5-7577-0740-2

ISBN 978-5-7577-0739-6 (Том 1)

Минимальные системные требования:

Компьютер: процессор x86 с тактовой частотой 500 МГц и выше; ОЗУ 512 Мб; 8Мб на жёстком диске; видеокарта SVGA 1280x1024 High Color (32 bit); привод CD-ROM.

Операционная система: Windows XP/7/8 и выше.

Программное обеспечение: Adobe Acrobat Reader версии 6 и старше.



ИТМО (Санкт-Петербург) — национальный исследовательский университет, научно-образовательная корпорация. Альма-матер победителей международных соревнований по программированию. Приоритетные направления: ИТ и искусственный интеллект, фотоника, робототехника, квантовые коммуникации, трансляционная медицина, Life Sciences, Art&Science, Science Communication.

Лидер федеральной программы «Приоритет-2030», в рамках которой реализуется программа «Университет открытого кода». С 2022 ИТМО работает в рамках новой модели развития — научно-образовательной корпорации. В ее основе академическая свобода, поддержка начинаний студентов и сотрудников, распределенная система управления, приверженность открытому коду, бизнес-подходы к организации работы. Образование в университете основано на выборе индивидуальной траектории для каждого студента.

ИТМО пять лет подряд — в сотне лучших в области Automation & Control (кибернетика) Шанхайского рейтинга. По версии SuperJob занимает первое место в Петербурге и второе в России по уровню зарплат выпускников в сфере ИТ. Университет в топе международных рейтингов среди российских вузов. Входит в топ-5 российских университетов по качеству приема на бюджетные места. Рекордсмен по поступлению олимпиадников в Петербурге. С 2019 года ИТМО самостоятельно присуждает ученые степени кандидата и доктора наук.

© Университет ИТМО, 2025

© Авторы, 2025

РЕДАКЦИОННАЯ КОЛЛЕГИЯ

Председатель: Белашенков Николай Романович, к.ф.-м.н., заместитель начальника департамента научных исследований и разработок ИТМО

Члены редколлегии:

Аббакумов Вадим Леонардович, к.ф.-м.н., доцент высшей школы цифровой культуры ИТМО

Азимов Рустам Шухратуллович, к.ф.-м.н., доцент высшей школы цифровой культуры ИТМО

Балакшин Павел Валерьевич, к.т.н., доцент факультета программной инженерии и компьютерной техники ИТМО

Бойцев Антон Александрович, к.ф.-м.н., доцент высшей школы цифровой культуры ИТМО

Волчек Дмитрий Геннадьевич, к.т.н., доцент высшей школы цифровой культуры ИТМО

Волынский Максим, доцент, к.т.н., директор, доцент научно-образовательной лаборатории "Техническое зрение" ИТМО

Графеева Наталья Генриховна, к.ф.-м.н., доцент высшей школы цифровой культуры ИТМО

Дмитриев Павел Иванович, к.т.н., научный руководитель ООО "НПП "Видеомикс"

Егорова Ольга Борисовна, к.филол.н, доцент высшей школы цифровой культуры ИТМО

Малых Валентин Андреевич, к.т.н., доцент высшей школы цифровой культуры ИТМО

Михайлова Елена Георгиевна, к.ф.-м.н., доцент, директор высшей школы цифровой культуры ИТМО

Павлова Елена Александровна, доцент, к.э.н., доцент факультета технологического менеджмента и инноваций ИТМО

Романов Алексей Андреевич, к.т.н., доцент высшей школы цифровой культуры ИТМО

Самарин Алексей Владимирович, к.ф.-м.н., доцент высшей школы цифровой культуры ИТМО

Силакова Любовь Владимировна, доцент, к.э.н., доцент факультета технологического менеджмента и инноваций ИТМО

Токман Мария Александровна, к.ф.-м.н., доцент высшей школы цифровой культуры ИТМО

ПРИКЛАДНАЯ АНАЛИТИКА

УДК 336.142.6

ЭНЕРГОПОТРЕБЛЕНИЕ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ: СИСТЕМНЫЙ ПОДХОД К ОПТИМИЗАЦИИ И УСТОЙЧИВОМУ РАЗВИТИЮ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Большаков Г.В.¹ (магистрант), Рогаткин Н.А.¹ (магистрант)
Научный руководитель – кандидат технических наук Бутылкина К.Д.¹
¹Университет ИТМО
zhora.vb@gmail.com

Аннотация

В работе рассматривается проблема роста энергопотребления нейросетевых моделей, сопровождающая стремительное развитие технологий искусственного интеллекта и глубокого обучения. Увеличение масштабов моделей, усложнение архитектур и рост вычислительной сложности приводят к значительным затратам энергии, что ограничивает возможности масштабирования и повышает углеродный след ИИ-инфраструктур. Цель исследования заключается в выявлении ключевых факторов, влияющих на энергетический профиль нейронных сетей, и в обосновании комплексного подхода к его оптимизации. Проанализированы современные методы снижения энергопотребления, включая прореживание, квантование, дистилляцию знаний, управление разреженностью активаций и использование энергоэффективных архитектур. Особое внимание уделено взаимодействию вычислительных и память-зависимых процессов, поскольку именно операции передачи данных становятся основным источником энергетических потерь. Показано, что наибольший эффект достигается при интеграции алгоритмических, аппаратных и инфраструктурных решений, обеспечивающих согласованное управление энергозатратами на всех уровнях жизненного цикла модели. В исследовании предлагается концепция «энергетического равновесия модели», основанная на балансе между вычислительной нагрузкой, точностью и устойчивостью. Сделан вывод, что переход к системному проектированию, учитывающему как вычислительные, так и энергетические ограничения, позволит формировать новое поколение нейросетевых систем, сочетающих высокую производительность, энергоэффективность и экологическую ответственность.

Ключевые слова

Энергопотребление нейросетей, энергоэффективность, оптимизация искусственного интеллекта, энергетическое равновесие.

Развитие технологий искусственного интеллекта и глубокого обучения в последние годы стало одной из главных движущих сил цифровой трансформации. Однако рост производительности и точности нейросетевых систем сопровождается значительным увеличением их энергопотребления. Современные модели, особенно большие языковые модели, требуют колоссальных вычислительных мощностей, что приводит к возрастающим затратам на электроэнергию и инфраструктуру. Обучение одной модели может обходиться в десятки мегаватт-часов, а углеродный след таких вычислений сопоставим с выбросами, создаваемыми тысячами автомобилей.

Существующие решения в области энергоэффективности сосредоточены в основном на оптимизации отдельных компонентов – алгоритмов, архитектур или аппаратных ускорителей. Однако их недостатком остаётся фрагментарность: снижение энергопотребления на одном уровне часто сопровождается потерей точности или ростом затрат на другом. Например, агрессивное квантование снижает энергопрофиль, но может вызвать деградацию точности; напротив, глубокие трансформерные архитектуры обеспечивают высокую производительность, но требуют огромных объёмов памяти и времени обучения. Проблема энергопотребления нейросетевых моделей требует системного подхода, объединяющего алгоритмические, аппаратные и инфраструктурные методы, что и является основной целью исследования.

Современные нейросети обладают миллиардами параметров и выполняют триллионы операций при обучении, что создаёт существенную нагрузку не только на вычислительные блоки, но и на систему памяти. По результатам исследования *Comparative Study on Energy Consumption of Neural Networks by Scaling of Weight-Memory Energy Versus Computing Energy for Implementing Low-Power Edge Intelligence*, значительная доля энергопотребления связана не с арифметическими операциями, а с передачей данных между уровнями памяти. Доступ к внешней памяти (DRAM) требует энергии, превышающей энергию вычислений более чем в 50 раз. Это особенно критично для архитектур типа трансформеров, где механизмы внимания предполагают частое обращение к весам и активациям, что делает модель «память-зависимой». В противоположность этому, сверточные сети при больших батчах чаще оказываются ограничены вычислительной мощностью, а не памятью, что подтверждает необходимость дифференцированного подхода к оптимизации [2].

Одним из ключевых направлений оптимизации является сокращение числа вычислений и обращений к памяти. В последние годы активно развиваются методы прореживания (pruning), когда избыточные связи и нейроны удаляются без существенного влияния на качество. По данным исследования *The Relationship between Sparseness and Energy Consumption of Neural Networks*, структурное прореживание позволяет снизить энергопотребление до 40% при сохранении точности после дообучения. Эффект усиливается, если применяется адаптивная схема, в которой веса удаляются постепенно и проверяется влияние каждого шага на конечный результат [3].

Другим важным инструментом является квантование (quantization), то есть переход к использованию чисел с меньшей разрядностью. Замена 32-битных весов на 8-битные значения снижает энергоёмкость операций примерно на 70%, поскольку уменьшается не только вычислительная нагрузка, но и объём передаваемых данных. При этом современные методы смешанной точности (mixed precision), описанные в *Zeus: Understanding and Optimizing GPU Energy Consumption of DNN Training*, позволяют достичь баланса между скоростью, стабильностью и энергозатратами, обеспечивая почти ту же точность, что и при полном 32-битном обучении [4].

Отдельного внимания заслуживает подход дистилляции знаний (knowledge distillation), при котором компактная модель обучается под «руководством» более крупной. Это позволяет сохранять качество при значительно меньшем числе параметров и, следовательно, при меньших энергозатратах. В исследовании *Comparative Study on Energy Consumption of Neural Networks by Scaling of Weight-Memory Energy Versus Computing Energy for Implementing Low-Power Edge Intelligence* показано, что сочетание дистилляции и автоматического поиска архитектуры (Neural Architecture Search, NAS) может уменьшить энергопотребление более чем на 80% при минимальной потере точности. Дополнительный потенциал снижения энергии кроется в управлении разреженностью активаций. Если часть нейронов временно не активна, система не тратит энергию на их обработку. Механизмы динамической активации, когда сеть самостоятельно определяет, какие узлы включать при конкретных входных данных, снижают энергопотребление до 30%. Такие методы особенно перспективны для реализации на периферийных устройствах (edge devices), где каждый миллиджоуль имеет значение [2, 3].

Оптимизация энергопотребления невозможна без учёта архитектуры аппаратного обеспечения. Как показано в исследованиях, современные вычислительные платформы не всегда проектируются с прицелом на энергоэффективность, а потому узким местом часто становится подсистема памяти. Использование кеш-ориентированных решений, когда рабочие наборы данных и весов полностью помещаются в быстродействующую память, даёт значительное снижение энергопотерь. Разработчики всё чаще прибегают к разделению больших моделей на фрагменты, соответствующие размерам кеша, или распределённой обработке по нескольким ускорителям, что уменьшает необходимость обращения к энергоёмкой внешней памяти. Эффективность также повышается за счёт применения специализированных ускорителей – ASIC, FPGA и TPU. Эти устройства спроектированы с учётом специфики нейросетевых операций и способны обеспечивать в десять раз более высокую производительность на ватт по сравнению с традиционными GPU. Дополнительное

преимущество даёт технология динамического масштабирования напряжения и частоты (Dynamic Voltage and Frequency Scaling, DVFS), позволяющая подстраивать параметры питания под текущие вычислительные потребности, снижая потребление энергии без заметных потерь производительности [2, 4].

Не менее важен инфраструктурный аспект. Дата-центры, обслуживающие обучение и вывод нейросетей, потребляют значительные объёмы энергии не только на сами вычисления, но и на охлаждение, вентиляцию и резервирование питания. В исследовании Zeus: Understanding and Optimizing GPU Energy Consumption of DNN Training отмечается, что энергетическая эффективность дата-центров искусственного интеллекта напрямую зависит от географического размещения: в холодных регионах расходы на охлаждение могут быть снижены почти вдвое. В связи с этим перспективным направлением является создание северных кластеров, использующих низкие температуры и возобновляемые источники энергии. В долгосрочной перспективе целесообразно развитие энергетически автономных дата-центров, питающихся от атомных станций или гидроэнергетических комплексов, что обеспечит стабильную и устойчивую работу инфраструктуры искусственного интеллекта [4].

Для успешного внедрения описанных подходов необходима чёткая методология измерения энергопотребления. Как показывают результаты работ, использование инструментов мониторинга (например, NVIDIA-SMI, Intel Power Gadget, EnergyFlow) позволяет отслеживать энергозатраты на уровне отдельных операций и этапов обучения. На основе таких данных можно строить энергетические профили моделей, выявлять узкие места и определять оптимальные конфигурации. В научной среде активно обсуждаются универсальные метрики – Energy-Per-Accuracy (EPA) и Joules-Per-Iteration (JPI), которые позволяют сравнивать энергоэффективность различных архитектур и алгоритмов независимо от их типа и масштаба. Результаты экспериментальных исследований подтверждают, что комплексное применение нескольких методов даёт наилучший эффект. Квантование в сочетании с прореживанием снижает энергопотребление в среднем на 65-70%, а добавление дистилляции повышает эффективность до 80%. В тех случаях, когда обучение проводится на специализированных ускорителях, общая энергоэффективность системы увеличивается до десятикратных значений по метрике операций на ватт. Таким образом, именно интеграция алгоритмических и аппаратных мер даёт синергетический эффект, недостижимый при использовании отдельных подходов [1, 3, 5].

В результате можно сделать вывод, что энергопотребление нейросетевых моделей является не только техническим параметром, но и стратегическим фактором, определяющим устойчивость развития искусственного интеллекта. Без продуманных мер по снижению энергозатрат масштабирование ИИ-систем может стать неустойчивым с точки зрения экономики и экологии. Однако существующие исследования и технологии показывают, что грамотное сочетание алгоритмических оптимизаций, архитектурных решений и инфраструктурных преобразований позволяет добиться существенного прогресса.

Современный подход к оптимизации должен рассматривать энергопотребление как интегральную характеристику модели, зависящую от структуры нейросети, используемого оборудования и особенностей обучения. Такой взгляд позволяет переходить от разрозненных мер к целостной стратегии, где энергия рассматривается наряду с точностью и скоростью. В данной работе предложено рассматривать этот баланс как фундаментальный принцип построения устойчивых нейросетевых систем. Концепция «энергетического равновесия модели» предполагает, что проектирование архитектуры, выбор метода обучения и подбор аппаратных параметров должны осуществляться согласованно, с учётом не только вычислительных, но и энергетических ограничений. Сформулированные в исследовании положения позволяют обобщить современные результаты и предложить практическое направление для дальнейших работ – переход от оценки эффективности моделей по точности к комплексной оценке по критерию «энергия-точность-устойчивость». Развитие подобных принципов способно стать основой нового этапа проектирования ИИ-систем, в которых технологическое развитие будет сочетаться с ответственным и рациональным использованием энергетических ресурсов.

Литература

1. Measuring the Energy Consumption and Efficiency of Deep Neural Networks: An Empirical Analysis and Design Recommendations [Электронный ресурс]. Режим доступа: <https://algoritmosverdes.gob.es/sites/default/files/2025-01/Measuring%20the%20Energy%20Consumption%20and%20Efficiency%20of%20Deep%20Neural%20Networks%20-%20An%20Empirical%20Analysis%20and%20Design%20Recommendations.pdf> (Дата обращения 30.10.2025).
2. Comparative Study on Energy Consumption of Neural Networks by Scaling of Weight-Memory Energy Versus Computing Energy for Implementing Low-Power Edge Intelligence [Электронный ресурс]. Режим доступа: https://www.researchgate.net/publication/393494773_Comparative_Study_on_Energy_Consumption_of_Neural_Networks_by_Scaling_of_Weight-Memory_Energy_Versus_Computing_Energy_for_Implementing_Low-Power_Edge_Intelligence (Дата обращения 30.10.2025).
3. The Relationship between Sparseness and Energy Consumption of Neural Networks [Электронный ресурс]. Режим доступа: <https://pmc.ncbi.nlm.nih.gov/articles/PMC7710421/pdf/NP2020-8848901.pdf> (Дата обращения 30.10.2025).
4. Zeus: Understanding and Optimizing GPU Energy Consumption of DNN Training [Электронный ресурс]. Режим доступа: <https://par.nsf.gov/servlets/purl/10402187> (Дата обращения 30.10.2025).
5. PolyThrottle: Energy-efficient Neural Network Inference on Edge Devices [Электронный ресурс]. Режим доступа: <https://arxiv.org/pdf/2310.19991> (Дата обращения 30.10.2025).

УДК 004.832.28

ВЛИЯНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА НА ТРАНСФОРМАЦИЮ ИНДУСТРИИ РАЗВЛЕЧЕНИЙ

**Большаков Г.В.¹ (магистрант), Новиков В.В.¹ (магистрант), Рогаткин Н.А.¹ (магистрант)
Научный руководитель – кандидат технических наук Бутылкина К.Д.¹**

¹Университет ИТМО
zhora.vb@mail.ru

Аннотация

В статье рассматривается влияние искусственного интеллекта на различные направления индустрии развлечений: цифровое искусство, комиксы, кино, мультипликацию, музыкальную и литературную сферы, а также игровую индустрию. Показано, что нейросети становятся инструментом, способным не только ускорить и удешевить процесс создания контента, но и расширить творческие возможности авторов. На основе данных аналитических отчётов Kert, KPMG, МФТИ, HeadHunter и Сколково выявлено, что более 60% дизайнеров уже применяют генеративные модели в работе, а использование искусственного интеллекта сокращает время на создание визуальных и звуковых материалов в среднем на 20-30%. Отмечается демократизация творчества: независимые авторы и небольшие команды могут создавать конкурентоспособные продукты без крупных вложений. Вместе с тем подчеркиваются ограничения генеративных моделей в области сюжетостроения и художественной целостности, что сохраняет за человеком ключевую роль в креативных процессах. Авторы делают вывод о формировании нового типа взаимодействия человека и машины, где искусственный интеллект выступает не заменой, а партнёром в создании культурных продуктов, способствуя развитию инноваций, междисциплинарных связей и новых форм творчества.

Ключевые слова

Искусственный интеллект, индустрия развлечений, цифровое искусство, генеративные модели.

Тренд на внедрение искусственного интеллекта в разные сферы жизни набирает обороты с каждым днём, он не обошёл стороной и индустрию развлечений. Корпорации и маленькие команды могут использовать искусственный интеллект для ускорения и удешевления производства. Творцы-одиночки с помощью нейросетей могут воплощать свои идеи гораздо проще чем раньше. В разных видах развлечений это проявляется по-разному, поэтому мы рассмотрим их отдельно.

В индустрии создания цифровых рисунков нейросети могут использоваться художниками для генерации референсов или заготовок для итогового рисунка. Более опытные в использовании нейросетей люди могут просто обычной генерацией создавать качественные изображения. После обработки в редакторах изображений, к примеру, Adobe Photoshop, и нескольких штрихов, такие изображения могут соревноваться по качеству с рисунками выдающихся цифровых художников. Согласно исследованию Kert, уже более 60% дизайнеров и иллюстраторов используют генеративные модели (Midjourney, DALL-E, Kandinsky) для ускорения работы, а 42% компаний в медиаиндустрии рассматривают искусственный интеллект как часть творческого процесса, а не замену художников. Генерация изображений также может использоваться в разных частях рисунка, нейросеть может сгенерировать фон, одежду, или самого персонажа. Для этих задач можно использовать разные нейросети, специализирующиеся на конкретных задачах чтобы получить более качественное итоговое изображение. В целом создание цифровых рисунков с помощью нейросетей несложное занятие, и количество энтузиастов в этой сфере огромное [1].

Стоит также упомянуть что в смежной к цифровым рисункам индустрии – индустрии комиксов и манги, также могут использоваться нейросети. Модели, натренированные для помощи художникам манги встречаются в интернете и могут помочь сделать больший объём работы за меньшее количество времени. В отчете МФТИ отмечается, что использование искусственного интеллекта для фонов и второстепенных персонажей позволяет сократить время на выпуск одной главы манги в среднем на 27% [3].

В киноиндустрии нейросети тоже имеют несколько полезных инструментов. Полностью сгенерированные кадры нейросетью получаются не очень качественными, и вряд ли будут

привлекать зрителя. По данным KPMG, несмотря на активное развитие генеративных моделей видео, таких как Sora 2, качество по-прежнему недостаточно для массового применения в кино. Зато в этой области стоит обратить внимание на генерацию голоса и видеоизображения актёров. Такие инструменты обычно применяются в случае, если актёр погиб, или не может присутствовать на съёмках по каким-либо причинам. Также нейросети могут помочь с созданием красивой и более дешёвой в производстве графики. Kert указывает, что искусственный интеллект снижает стоимость постпродакшна на 15–20% при сохранении художественного качества [1, 2].

Индустрии мультипликации повезло меньше, как было упомянуто ранее, Sora 2 и прочие генеративные нейросети не способны пока что создавать качественные видео. С другой стороны, в мультипликации всю озвучку можно передать нейросетям, достаточно получить разрешение на использовании голоса у актёра. Это позволит сократить время и бюджеты на запись звука. Согласно отчёту «От пилота к масштабу» от Сколково, около 30% российских студий уже тестируют системы синтеза речи на основе искусственного интеллекта для дубляжа и анимации. Также концепт-арты и фоны можно сгенерировать, а затем немного доработать, это сильно уменьшит затраты на художников. Генерацию графики тоже можно использовать, но для этого скорее всего придётся создавать собственную модель, что дорого и не всегда оправданно [5].

В случае 3D мультипликации же появляется возможность генерировать 3D модели и после отдавать их на доработку художникам. Это тоже позволяет экономить и ускорять производство.

В музыкальной индустрии довольно много ИИ-энтузиастов, как это было в индустрии цифровых рисунков. Нейросети в этой сфере позволяют как генерировать абсолютно новые треки с разными стилями и голосами, так и создавать каверы на уже существующие. Отчёт МФТИ подчёркивает, что технологии генерации музыки на основе больших языковых моделей (LLM-based composition) уже применяются для коммерческих треков, а в 2024–2025 годах количество «AI-музыкантов» выросло на 37%. Нынешние нейросетевые инструменты позволяют создавать разные варианты песен и альбомов, к примеру, переделать тяжёлый рок в city pop japan 80th, это можно использовать для повторного заработка на популярной музыке лейбла. Также можно создавать абсолютно новых несуществующих в реальности исполнителей как Hatsune Miku (у неё другая технология в основе, но пример хорошо иллюстрирует возможность). Одиночные же творцы с интересной идеей, но отсутствием голоса или же навыков в создании мелодий могут попробовать заменить одну из составляющих нейросетью, что сильно демократизирует индустрию и уменьшает порог входа. С другой стороны, это создаёт больше конкуренции и требование к интересной идее возрастает. Многие творцы на youtube заказывают простые анимации и арты у художников для привлечения к себе внимания, учитывая простоту этих анимаций, можно вместо заказа у художника использовать нейросетевую генерацию. По данным HeadHunter, за последний год спрос на музыкальных продюсеров с навыками работы с искусственным интеллектом вырос на 23%, а доля вакансий, связанных с генеративным контентом, увеличилась почти вдвое [3, 4].

Индустрия писателей получила самый спорный инструмент – языковые модели, такие как chatgpt, deepseek, grok и другие. Может показаться что языковая модель может написать сценарий или книгу, но, как и в случае с генерацией видео, качество таких сюжетов будет слишком низким. Нейросеть не умеет мыслить, она не способна составлять логические цепочки. Скорее всего истории сгенерированные нейросетью всегда будут наполнены бесконечным количеством логических ошибок, что сильно снижает качество истории и делает её абсолютно не интересной читателю. Стоит зайти с другой стороны, нейросети могут помочь с придумыванием неожиданных сюжетных поворотов. МФТИ и Kert отмечают, что использование LLM-моделей на этапе «идейной генерации» повышает разнообразие сюжетов и ускоряет сценарный процесс в среднем на 40%. Текстовые модели всегда можно попросить сгенерировать описание внешности, локаций, имена персонажей. В итоге приходим к такому сценарию – основной сюжет и логические цепочки остаются за человеком, а рутинные задачи описания можно оставить нейросетям. Но текст в любом случае лучше редактировать

человеку. Такой сценарий использования сильно сократит время написания, так как рутина отмечается и остаётся машине [1, 3].

Самые же большие возможности нейросети открывают для создателей-одиночек в игровой индустрии. Для корпораций тоже существует много интересных инструментов, но самые большие возможности нейросети дают именно инди-разработчикам.

Игровая индустрия комплементирует все предыдущие индустрии, она использует цифровые рисунки, анимацию, 3D модели, мультипликацию, видео, музыку и текст, добавляя к этому геймплей. Поэтому все инструменты, которые были описаны ранее, можно использовать и здесь.

Корпорации могут уменьшить затраты на художников и 3D художников внедряя нейросети в их работу, тоже относится и к сценаристам. С музыкой сложнее, так как корпорации пока не научились работать с музыкой с помощью нейросетей. По отчёту KPMG, 35% игровых студий в мире уже интегрировали генеративные инструменты в пайплайн производства, а использование искусственного интеллекта в кодировании (Copilot, ChatGPT, Devin) позволяет сократить время разработки на 25–30% [2].

Творцам одиночкам нейросети дают шанс показать себя. Если у них есть интересная идея и достаточно усердия, то сейчас лучший момент для создания своей игры. Деньги на художников и композиторов на начальных этапах не нужны, картинки и музыку для игры можно сгенерировать. Для создания игры остаётся два компонента - программный код и геймплей. Программный код человек может как написать сам, так и научиться в процессе написания игры, параллельно запрашивая помощь у нейросетей. В 2025 году благодаря существованию нейросетей всегда есть возможность спросить, как работает та или иная часть кода, без ожидания ответа на вопрос в течение нескольких дней на профильных сайтах. Геймплей же является проверкой насколько идея творца интересна, это основная творческая задача, которую ему предстоит решить. Это причина почему в его игру люди могут захотеть играть, так как всё остальное будет сгенерировано нейросетью, и особой ценности не представляет. Также в игру можно добавить сюжет, но для инди-игры он не так важен.

После того как человек создаст минимально рабочую версию игры, которая, по его мнению, может заинтересовать игроков, он может выпустить демоверсию или ранний доступ, благодаря которым можно привлечь внимание и финансирование для дальнейшей разработки. После этого можно уже музыку и арты заказывать у художников. Нейросети в данном случае дают человеку возможность создать минимальную версию игры и проявить себя. В будущем мы возможно увидим несколько проектов с таким путём разработки. Также это один из самых дешёвых способов разработки игр.

В итоге мы видим, что нейросетевые технологии довольно сильно меняют индустрию развлечений. Где-то они просто помощники, где-то они многое меняют, заставляя работников переучиваться и вызывая большие сокращения. А где-то они дают возможность, о которой раньше никто даже не мечтал.

Литература

1. Kept. Вызовы и возможности использования ИИ в практике цифровой трансформации [Электронный ресурс]. Режим доступа: <https://assets.kept.ru/upload/pdf/2025/09/ru-ai-in-consumer-markets-report.pdf> (Дата обращения 30.10.2025).
2. KPMG. AI Workforce: From Hype to Hard Truths [Электронный ресурс]. Режим доступа: <https://assets.kpmg.com/content/dam/kpmgsites/uk/pdf/2025/09/ai-workforce-from-hype-to-hard-truths.pdf> (Дата обращения 30.10.2025).
3. МФТИ; Национальная технологическая инициатива. Искусственный интеллект: Индекс искусственного интеллекта. [Электронный ресурс]. Режим доступа: https://psv4.userapi.com/s/v1/d2/szsdQk57xxHK-pTl17vQcSDWXzmBu3yJtqm2FQfn8L_6JX7quH9k6m0JyjQcBFYulZkhrMPqOmI9XL3opjB-Wrj9tx3qpD7-z18LIX2mRnOj2TLEIw1qTYXan7pifSaxsJDtxMUdodGe/MFTI_NTI_Iskusstvennyi_774_Intellekt_Iskusstvennyi_774_intellekt_sentyab.pdf (Дата обращения 30.10.2025).

4. HeadHunter. Краткий обзор рынка труда. Сентябрь 2025 [Электронный ресурс]. Режим доступа: <https://hhcdn.ru/file/18240347.pdf> (Дата обращения 30.10.2025).
5. Сколково. От пилота к масштабу: как встроить ИИ в процессы и получить эффект [Электронный ресурс]. Режим доступа: https://sk.skolkovo.ru/storage/file_storage/7f294266-c1ec-472a-8180-2357c91d9e47/От-пилота-к-масштабу_исследование-Лаборатории-ИИ-СКОЛКОВО.pdf (Дата обращения 30.10.2025).

УДК 336.142.6

ПЕРСПЕКТИВЫ ВНЕДРЕНИЯ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ АНАЛИЗА КУРСА ВАЛЮТ

Кушнер Д.В.¹ (бакалавр), Тимофеева С.М.¹ (бакалавр)

Научный руководитель – магистр наук в области менеджмента Жанабаева А.С.¹

¹Восточно-Казахстанский технический университет им. Д. Серикбаева

dmitrykushnerr@yandex.ru; sofitimofeeva_2004@mail.ru

Аннотация

В статье исследуется применение методов машинного обучения (МО) для прогнозирования курса казахстанского тенге к доллару США. Показано, что МО дополняет классические экономические модели, позволяя одновременно учитывать разнообразные высокочастотные и фундаментальные факторы — исторические ряды KZT/USD, цены на нефть (Brent), индекс доллара (DXY), Tenge OverNight Index Average (TONIA), инфляцию, процентные ставки, международные резервы, торговый баланс и новостной фон. Описаны ключевые этапы построения модели для прогноза временных рядов. Отдельно рассматриваются особенности работы с временными рядами и преимущества ансамблевых алгоритмов, в частности градиентного бустинга, который способен выявлять сложные нелинейные взаимосвязи и повышать точность прогнозов. Дана практическая рекомендация: для краткосрочных прогнозов приоритетно использовать высокочастотные индикаторы (нефть, новости, TONIA и пр.), а для долгосрочных — фундаментальные макропоказатели. Подчёркивается необходимость сочетания экономической экспертизы и МО для обеспечения интерпретируемости и устойчивости прогнозов, а также внимание к рискам переобучения и регулярной переоценке моделей в изменяющихся рыночных условиях. Работа полезна для аналитиков, инвесторов и государственных органов, заинтересованных в повышении точности валютных прогнозов.

Ключевые слова

Прогноз курса валют, тенге, доллар, KZT, USD, машинное обучение, градиентный бустинг.

Введение

В условиях нестабильных мировых рынков и высокой волатильности сырьевых цен прогнозирование курса одной национальной валюты к другой стало не просто академической задачей, а практической необходимостью для бизнеса, банков и государственных органов. Традиционные экономические модели дают важные инсайты, но часто не успевают учесть одновременно большое количество разнородных факторов — от изменений цены на нефть до краткосрочных новостей и потоков капитала. Здесь на помощь приходит машинное обучение (МО) — инструмент, который умеет находить скрытые закономерности в больших объемах данных и выдавать количественные прогнозы.

Машинное обучение не отменяет экономической логики, но дополняет её: вместо единой формулы модель рассматривает много признаков одновременно (лаговые значения курса, нефти, резервов, процентных ставок, индикаторов инфляции, новостных сигналов) и учится прогнозировать будущее из прошлого. Это позволяет получать более гибкие прогнозы, быстро проверять гипотезы и строить сценарии — от краткосрочных торговых сигналов до долгосрочных оценок риска.

В этой статье будет объяснено для широкого круга читателей, как работает машинное обучение в задачах валютного прогнозирования, какие данные и признаки следует использовать для модели курса тенге к доллару, какие алгоритмы стоит попробовать и каких ошибок стоит избегать.

Причины доминирования доллара

Во второй половине XX века доллар США закрепился в роли мировой резервной валюты. После двух мировых войн экономика США оказалась сильнее европейских: у Америки были крупные золотовалютные резервы, разветвлённая банковская система и статус крупнейшего кредитора. На конференции в Бреттон-Вудсе (июль 1944 года) была создана международная система, при которой большинство валют привязывались к доллару, а сам доллар — к золоту, а именно 35 долларов США за 1 тройскую унцию (31,1 грамм) [1]. Это решение фактически

сделало доллар мировой валютой в международной торговле и расчётах, а также основным резервным активом центробанков.

Со временем привязка к золоту была отменена (начало 1970-х), но уже сложившаяся инфраструктура — ликвидные финансовые рынки в долларах, международные институты и привычка расчётов в этой валюте — сохранила её ведущую роль. Кроме того, многие сырьевые товары (в первую очередь, нефть) традиционно котируются в долларах, что дополнительно укрепляет влияние американской валюты на глобальные потоки капитала.

Экономические показатели, используемые в моделях прогнозирования курса тенге

При прогнозировании курса казахстанского тенге и других валют необходимо полагаться на основные показатели, существенно влияющие на них.

Для построения точных и устойчивых прогнозов курса тенге к доллару США важно учитывать разнообразие факторов, отражающих как краткосрочные рыночные колебания, так и долгосрочные макроэкономические тенденции. Эти показатели можно условно разделить на две группы — оперативные (высокочастотные) и фундаментальные (низкочастотные). Первые часто обновляются и реагируют на рыночные ожидания, что является преимуществом при краткосрочном прогнозе. Фундаментальные показатели наоборот образуют долгосрочные тренды валют.

Фундаментальные (низкочастотные) показатели

Уровень инфляции один из важных показателей, поскольку с высоким уровнем рыночных цен стоимость валюты будет снижаться. Повышенный спрос на иностранные валюты приводит к их удорожанию на валютном рынке. Также иностранные инвесторы и импортёры теряют интерес к валюте, потому что она становится менее стабильной [2].

Повышение процентных ставок делает страну более привлекательной для иностранных инвесторов, увеличивая спрос на её валюту и укрепляя её курс. Всё происходит благодаря тому, что высокие ставки предлагают более высокую доходность по депозитам и облигациям, а низкие ставки удешевляют кредиты. Этот приток капитала увеличивает спрос на национальную валюту на рынке, что ведет к укреплению её курса.

Оперативные (высокочастотные) показатели

Индекс доллара (DXY) — он показывает общую силу американского доллара относительно других мировых валют и влияет на глобальные финансовые рынки. Его значение помогает понять, как будет меняться стоимость товаров, цены на сырьё, а также влияет на торговые операции и валютные пары по всему миру. Например, большинство сырьевых товаров и металлов котируются в долларах, поэтому рост индекса данной валюты часто приводит к снижению цен на сырьё, и наоборот.

Цена на нефть — необходимо учитывать, что доллар привязан к нефти, поскольку США являются одним из добытчиков и одним из крупнейших потребителей нефти. Таким образом, при изменении цены на нефть оказывается влияние на доллар, что, в свою очередь, влияет на валютный рынок [3].

В совокупности эти показатели позволяют формировать более точные прогнозы валютных колебаний и оценивать степень устойчивости национальной экономики к внешним и внутренним шокам.

Показатели, изменяющиеся на ежедневной основе

Эта группа факторов наиболее чувствительна к рыночным колебаниям и отражает динамику текущих ожиданий инвесторов, потоков капитала и ценовых трендов. Они особенно полезны для краткосрочного и среднесрочного прогнозирования (от одного дня до нескольких недель):

- исторический курс пары KZT/USD. Основной источник информации о динамике валютного рынка, а также используется как базовая временная серия для обучения модели;
- новостной фон и политические события. Включает данные о санкциях, геополитических рисках, экономических заявлениях и других событиях, влияющих на ожидания участников рынка (для автоматизации анализа могут применяться методы обработки естественного языка — *sentiment analysis*);

- решения по базовой ставке. Изменения ключевой ставки Национального банка Казахстана напрямую влияют на доходность тенговых активов и, как следствие, на курс национальной валюты;
- индекс потребительских цен (CPI). Отражает инфляционные тенденции и формирует ожидания по денежно-кредитной политике;
- кросс-курсы KZT/RUB и USD/Gold. Позволяют оценивать влияние соседних валют и глобальных трендов. Например, перехода капитала в «тихие гавани», т.е. перемещение средств в активы, считающиеся наиболее безопасными в периоды экономической нестабильности или кризиса;
- курс KZT/Gold. Важен как индикатор внутренней покупательной способности национальной валюты относительно защитных активов. Также он помогает понять, насколько сильно внутренние и внешние процессы отражаются на казахстанском тенге;
- показатель TONIA (Tenge OverNight Index Average). Отражает краткосрочную ликвидность на внутреннем денежном рынке и может сигнализировать о межбанковом напряжении или избытке ликвидности. Историческое значение показателя TONIA состоит в том, что он стал ключевым безрисковым ориентиром денежного рынка в Казахстане и играет важную роль в его реформировании;
- курс USD/Brent. Сильнейший внешний фактор для Казахстана, поскольку цены на нефть определяют валютные поступления и торговый баланс. Рост цены на нефть сигнализирует об увеличении мирового спроса или сокращении предложения, а падение — наоборот;
- индекс доллара (DXY). Служит индикатором глобальной силы доллара: его рост часто сопровождается ослаблением валют развивающихся стран, включая тенге. Сильный доллар обычно оказывает давление на цены сырьевых товаров, которые номинированы в долларах. Ослабление доллара, наоборот, может способствовать росту цен на сырье.

Показатели, изменяющиеся на ежегодной основе

Эти макроэкономические переменные характеризуют фундаментальное состояние экономики и применяются преимущественно для долгосрочного прогнозирования. Срок прогноза составляет от квартала до нескольких лет:

- процентные ставки основных валют. Влияют на направление международных потоков капитала и дифференциал доходности активов, номинированных в тенге и долларах;
- международные резервы Национального банка Казахстана. Отражают способность государства сглаживать колебания курса и обеспечивать валютную стабильность. Наличие достаточных резервов так же укрепляет доверие к национальной валюте и финансовой системе. Это сигнализирует рынку, что Национальный банк обладает необходимыми инструментами для защиты тенге;
- объёмы экспорта и импорта. Формируют торговый баланс и напрямую определяют спрос и предложение иностранной валюты;
- денежные переводы и миграционные потоки. Особенно актуальны в контексте экономических связей с Россией. Они влияют на внутренний спрос на иностранную валюту и ликвидность на рынке. Денежные переводы играют важную роль в платёжном балансе страны, помогая сбалансировать его. Они способствуют региональному развитию и сглаживанию экономических дисбалансов;
- валовой внутренний продукт (ВВП). Интегральный показатель экономической активности и устойчивости, влияющий на долгосрочные ожидания инвесторов и кредитные рейтинги страны.

Машинное обучение и обработка информации с его помощью

Машинное обучение — это один из способов научить компьютер давать прогнозы или принимать решения, опираясь на данные. Вместо того чтобы писать жесткие правила («если X — то Y»), как при написании обычных алгоритмов, не использующих МО, разработчик предоставляет компьютеру исторические данные, и компьютер сам находит закономерности, которые затем используются для предсказания будущего. Несложно заметить, что машинное обучение во многом похоже на процесс человеческого обучения. Когда человек сталкивается с

новыми ситуациями, он делает выводы из прошлых наблюдений: запоминает, что при одних условиях результат был успешным, а при других — нет. Со временем мозг формирует «внутренние правила», по которым человек принимает решения. Точно так же и модель машинного обучения «изучает» данные, ищет в них закономерности и вырабатывает собственные зависимости между входами и результатами. Разница лишь в том, что человек использует интуицию и опыт, а машина — математические алгоритмы и вычисления. Но цель одна: научиться распознавать шаблоны в прошлом, чтобы предсказывать будущее [4].

Рассмотрим основные стадии применения машинного обучения в прогнозировании:

1. Собираем данные. При чем, чем больше и качественнее история, тем лучший результат получим на выходе
2. Готовим признаки. Из «сырой» информации делаем понятные входы: прошлые изменения курса, инфляция, цена нефти, ставка НБК и т.п.
3. Обучаем. В процессе обучения компьютер находит связь между признаками и тем, что надо предсказать (например, курс через неделю).
4. Проверяем. Модель проверяют на данных, которых она не видела, чтобы убедиться, что она не «запомнила» прошлое, а действительно научилась прогнозировать.
5. Используем и сравниваем. Модель испытывают на реальных данных или используют для анализа, но постоянно отслеживают её качество — экономические условия меняются.

Так как задача прогнозирования курса валют относится к классу задач прогнозирования временных рядов, при котором каждое следующее наблюдение зависит от предыдущих во времени [5]. То есть, значение сегодняшнего курса тесно связано с тем, каким оно было вчера, неделю или месяц назад. Поэтому при анализе таких данных важно учитывать временную последовательность и динамику изменений.

В отличие от обычных задач регрессии (задач, которые прогнозируют числовые данные) где примеры независимы друг от друга, временные ряды требуют от модели умения распознавать тренды, сезонность и краткосрочные колебания. Именно поэтому для таких задач применяются специальные подходы и алгоритмы, способные учитывать эти закономерности.

Одним из наиболее эффективных инструментов машинного обучения для прогнозирования временных рядов является градиентный бустинг, суть которого состоит в последовательном обучении нескольких деревьев решений, где каждое новое дерево улучшает результат предыдущего.

1. Первое дерево делает начальный прогноз. Например, оно может выдать среднее значение курса или грубую оценку по базовым признакам.
2. Вычисляется ошибка (остаток) — разница между тем, что модель предсказала, и реальным значением курса.
3. Следующее дерево обучается предсказывать именно эту ошибку, то есть оно пытается понять, в каких случаях первая модель ошибалась и насколько.
4. Затем новое дерево добавляется к общей модели с небольшим весом (дополнительным балансирующим параметром в уравнении), чтобы не переобучиться.
5. Процесс повторяется большое количество раз, при чем, каждое дерево учится исправлять ошибки всех предыдущих. В итоге ансамбль деревьев можно сравнить с группой аналитиков, где каждый последующий специалист уточняет прогноз своего коллеги.
6. В конце получаем финальный прогноз, который учитывает, как краткосрочные, так и сложные нелинейные зависимости между факторами.

С графической визуализацией алгоритма градиентного бустинга можете ознакомиться на рисунке.

Заключение

Алгоритмы машинного обучения — мощный инструмент для анализа и прогнозирования валютного курса, потому что они позволяют одновременно учитывать множество факторов: историю курса, макроэкономические индикаторы и даже информацию из новостей, и, без помощи данных, исследователю будет крайне затруднительно дать прогноз, учитывающий большинство факторов. Для краткосрочных прогнозов особенно полезны высокочастотные

данные (нефть, новости, TONIA и т. п.), тогда как фундаментальные показатели помогают формировать долгосрочный взгляд.




Рисунок. Схематическое представление процесса градиентного бустинга

Важно помнить: модель — это не замена экономического смысла, а его дополнение. Хорошая практика — сочетать экономическую экспертизу с МО-моделями. Применение подобных алгоритмов особенно полезно для многих, в том числе для предпринимателей и инвесторов, осуществляющих операции с иностранной валютой.

Литература

1. Почему доллар стал мировой валютой [Электронный ресурс] Режим доступа: <https://www.finam.ru/publications/item/pochemu-dollar-stal-mirovoy-valyutoy-20230718-1636/> (Дата обращения 18.10.2025).
2. Инфляция напрямую влияет на курс валюты [Электронный ресурс] Режим доступа: <https://www.tbank.ru/invest/social/profile/sidhartha/> (Дата обращения 18.10.2025).
3. Анушко Д. А. Зависимость стоимости доллара от цены на нефть [Электронный ресурс] Режим доступа: <https://cyberleninka.ru/article/n/zavisimost-stoimosti-dollar-a-ot-tseny-na-neft/viewer> (Дата обращения 18.10.2025).
4. Серрано Л. Грокаем машинное обучение / пер. с англ. — М.: Питер, 2022. 320 с.
5. Грачев Д.В., Рязанов Н.А., Лимарев П.В. Анализ влияния инфляционных процессов на валютный курс [Электронный ресурс] Режим доступа: <https://cyberleninka.ru/article/n/analiz-vliyaniya-inflyatsionnyh-protsessov-na-valyutnyy-kurs/viewer> (Дата обращения 18.10.2025).

УДК 004

АНАЛИЗ И ПРОГНОЗИРОВАНИЕ ЭНЕРГОПОТРЕБЛЕНИЯ ПРОМЫШЛЕННЫХ ПРЕДПРИЯТИЙ С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ

Сорокин А.А.¹ (студент)

Научный руководитель – ассистент Захаров Д.Н.¹

¹Университет ИТМО

sorokinartem2506@gmail.com

Аннотация

В статье представлен метод анализа и прогнозирования энергопотребления промышленных предприятий на основе данных временных рядов. Применены методы машинного обучения: кластеризация KMeans для выявления режимов работы, алгоритм Random Forest для прогнозирования пиковых нагрузок и Isolation Forest для обнаружения аномалий. Полученные результаты позволяют оптимизировать работу предприятия и снизить расходы на электроэнергию.

Ключевые слова

Энергопотребление, промышленные предприятия, прогнозирование, машинное обучение, кластеризация, аномалии, временные ряды.

Введение

Энергопотребление промышленных предприятий считается ключевой составляющей себестоимости продукции и важным фактором устойчивого развития. В условиях роста тарифов на электроэнергию и повышения требований к энергоэффективности задача прогнозирования энергопотребления приобретает особую актуальность.

Традиционно для прогноза энергопотребления применяются статистические методы анализа временных рядов, такие как скользящее среднее или ARIMA¹. Однако эти подходы плохо учитывают сложную сезонность и нелинейные факторы, характерные для работы промышленного оборудования. Современные методы машинного обучения позволяют строить более точные модели, но зачастую их применение ограничивается отдельными задачами: либо прогнозирование, либо выявление аномалий.

Предлагаемый подход сочетает в себе элементы кластеризации и прогнозирования с использованием рекуррентных нейронных сетей LSTM², что обеспечивает как выявление аномальных пиков энергопотребления, так и построение прогноза на основе исторических данных. Таким образом, достигается двойной эффект: снижение риска перегрузок и оптимизация расходов на энергию.

Ранее исследователи в области прогнозирования показали, что ансамблевые методы машинного обучения, такие как Random Forest и Gradient Boosting, обладают высокой точностью в задачах краткосрочного прогнозирования энергопотребления. Так, Pop et al. показали, что использование ансамблей алгоритмов машинного обучения, в частности взвешенного сочетания Random Forest и Gradient Boosting, позволяет получить более точные результаты, чем применение каждого алгоритма по отдельности [1].

Другой значимый вклад был сделан Wang и соавт., которые предложили гибридный подход к обнаружению аномалий на основе прогнозирования временных рядов энергопотребления [2]. Сначала формируется высокоточный прогноз с использованием архитектур типа Autoformer³, а затем на основе анализа остатка выявляются аномалии. Такой подход существенно улучшает качество обнаружения отклонений и особенно полезен для промышленных предприятий, где аномалии могут приводить к серьезным сбоям.

Таким образом, анализ существующих решений показывает, что наиболее перспективными являются методы, объединяющие прогнозирование с дополнительными процедурами обработки данных – кластеризацией, анализом остатков или ансамблированием моделей.

¹ Модели вида ARIMA. <https://clck.ru/3PB2LV> (Дата обращения 12.09.2025)

² LSTM layer. https://keras.io/api/layers/recurrent_layers/lstm/ (Дата обращения: 12.09.2025)

³ Autoformer. <https://clck.ru/3PB3Af> (Дата обращения 12.09.2025)

Описание метода

В качестве исходных данных использован открытый набор Steel Industry Energy Consumption Dataset, содержащий показания энергопотребления предприятия по минутным интервалам [3].

На этапе предварительной обработки проведена стандартизация и преобразование данных:

- временные метки приведены к единому формату;
- пропуски заменены средними значениями (для энергопотребления) и линейной интерполяцией (для временных признаков);
- дополнительно выполнено построение дополнительных признаков, таких как скользящие средние (MA7, MA30), лаговые переменные (Lag1, Lag7), календарные индикаторы (час, день недели, месяц).

Результаты предобработки позволяют проследить динамику энергопотребления и выявить характерные закономерности.



Рис. 1. Динамика энергопотребления предприятия во времени

Для выявления типовых режимов потребления использован метод KMeans⁴. Кластеризация позволила разделить данные на три группы, соответствующие низкому, среднему и высокому уровням нагрузки. Кластеризация методом K-means направлена на разбиение набора данных на k кластеров, таких, что каждый объект принадлежит кластеру с ближайшим центром кластера. Цель алгоритма — минимизировать суммарное расстояние точек кластеров от их центров. Кластеризацию можно рассматривать как классификацию без размеченных данных (без учителя), то есть алгоритм должен классифицировать данные сам, без маркировки [4].



Рис. 2. Кластеры режимов энергопотребления

⁴ KMeans. <https://scikit-learn.org/stable/modules/generated/sklearn.cluster.KMeans.html> (Дата обращения: 12.09.2025)

Прогнозирование выполнено с использованием алгоритма Random Forest Regressor. В качестве признаков использовались:

- календарные индикаторы (час, день недели, месяц),
- скользящие средние (MA7, MA30),
- лаговые переменные (Lag1, Lag7).

Такая комбинация признаков позволяет учитывать сезонные колебания и автокорреляцию временного ряда. Фрагмент программного кода представлен ниже:

```
# Формирование признаков для модели
data['Hour'] = data.index.hour
data['DayOfWeek'] = data.index.dayofweek
data['Month'] = data.index.month
data['MA7'] = data['Usage_kWh'].rolling(window=7).mean().bfill()
data['MA30'] = data['Usage_kWh'].rolling(window=30).mean().bfill()
data['Lag1'] = data['Usage_kWh'].shift(1)
data['Lag7'] = data['Usage_kWh'].shift(7)
# Обучение модели Random Forest (на основании математической формулы 1)
model = RandomForestRegressor(n_estimators=200, random_state=42)
model.fit(X_train, y_train)
y_pred = model.predict(X_test)
# Определение пиковых нагрузок
threshold = y_test.mean() + 1.5*y_test.std()
peaks = y_test[y_test > threshold]
```

Обучение модели Random Forest заключается в построении ансамбля T деревьев решений $h_i(x)$, каждое из которых прогнозирует энергопотребление на основе входных признаков x_t .

Итоговое предсказание y_t формируется как среднее предсказаний всех деревьев:

$$\hat{y}_t = \frac{1}{T} \sum_{i=1}^T h_i(x_t), \quad (1)$$

где T – число деревьев в ансамбле, $h_i(x_t)$ – предсказание i -го дерева для признаков x_t , \hat{y}_t – итоговое предсказание энергопотребления в момент времени t .

Результаты, представленные на рисунке 3, показывают, что модель адекватно отражает сезонные колебания нагрузки и позволяет идентифицировать периоды пикового энергопотребления.




Рис. 3. Прогноз энергопотребления с пиковыми нагрузками

Для контроля качества работы модели используется средняя абсолютная ошибка MAE и RMSE [5]. Средняя абсолютная ошибка рассчитывается как среднее абсолютных разностей между целевыми значениями и значениями, предсказанными моделью на данном обучающем примере в процессе обучения:

$$MAE = \frac{1}{N} \sum_{i=1}^m |\gamma_i - \gamma_{ist_i}|, \quad (2)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^m (\gamma_i - \gamma_{ist_i})^2}, \quad (3)$$

где m – число объектов в обучающей выборке, γ_i – истинное значение, γ_{ist} – предсказанное значение моделью.

Визуализация контроля качества модели представлена на рисунках 4 и 5.




Рис. 4. Распределение ошибок прогнозирования



Рис. 5. Ошибки прогноза энергопотребления по времени

Эти результаты демонстрируют, что модель в целом устойчива, но наиболее значимые ошибки наблюдаются в периоды резких изменений нагрузки.

Для обнаружения нетипичных наблюдений в энергопотреблении применён алгоритм Isolation Forest⁵, основанный на случайных деревьях разбиений. Идея метода заключается в том, что аномальные точки легче «изолировать» при случайных разбиениях признакового пространства, чем обычные наблюдения. Фрагмент программного кода представлен ниже:

```
from sklearn.ensemble import IsolationForest

# Инициализация модели Isolation Forest
iso = IsolationForest(contamination=0.01, random_state=42)
data['Anomaly'] = iso.fit_predict(data[['Usage_kWh']])

# Выделение аномальных точек
anomalies = data[data['Anomaly'] == -1]
```

⁵ Isolation Forest. <https://clck.ru/3PB8MS> (Дата обращения 12.09.2025)

Каждая точка данных оценивается по метрике аномальности $s(x,n)$, которая зависит от средней глубины изоляции точки в ансамбле случайных деревьев (формула 4).

$$s(x, n) = 2^{-\frac{E(h(x))}{c(n)}}, \quad (4)$$

где $h(x)$ – глубина, на которой точка x была изолирована в дереве, $E(h(x))$ – средняя длина пути до изоляции по всем деревьям, $c(n)$ – нормирующий коэффициент для размера выборки n .

$$c(n) = 2H(n-1) - \frac{2(n-1)}{n}, \quad (5)$$

$$H(i) = \sum_{j=1}^i \frac{1}{j}. \quad (6)$$

Точки с $s(x,n)$ близкой к 0 считаются аномальными, а значения около 0.5–1 нормальными.

На рисунке 6 представлены выявленные аномалии, отмеченные красными точками. Анализ показал, что большинство аномалий коррелируют с пиковыми нагрузками и могут свидетельствовать о сбоях в оборудовании или особых технологических режимах, требующих внимания персонала.




Рис. 6. Выявленные аномалии энергопотребления

Результаты экспериментов

Проведённое исследование показало, что предложенный метод эффективно решает следующие задачи: выделяет характерные режимы энергопотребления, позволяет строить точные прогнозы и выявлять аномалии, коррелирующие с пиковыми нагрузками. Кластеризация режимов дала ясное разделение на низкие, средние и высокие нагрузки. Random Forest обеспечил высокую точность прогноза, подтверждённую визуализацией и расчетом MAE и RMSE. Методы выявления аномалий позволили обнаружить нестандартные точки, потенциально указывающие на сбои оборудования или особые технологические режимы.

Заключение

Предложенный гибридный подход доказал свою эффективность для анализа энергопотребления промышленного предприятия. В результате исследования удалось выделить типовые режимы энергопотребления, что позволяет более точно оценивать текущую нагрузку и прогнозировать пики.

Кроме того, построенная модель обеспечила точный прогноз энергопотребления с идентификацией пиковых нагрузок, что критически важно для оперативного управления и снижения энергетических затрат. Также проведённый анализ позволил выявить аномальные наблюдения, которые коррелируют с пиковыми нагрузками и могут указывать на сбои в работе оборудования или особенности технологических режимов.

Дальнейшие исследования могут быть направлены на интеграцию разработанного подхода в системы поддержки принятия решений, расширение признакового пространства с учётом технологических параметров производства, а также на применение методов глубокого обучения для повышения точности прогнозирования и более детальной интерпретации выявляемых аномалий.

Литература

1. Pop A., et al. Weighted ensemble of Random Forest and Gradient Boosting for short-term energy consumption forecasting // Energy Reports. 2022. Vol. 8. Pp. 1123–1135.
2. Wang J., Li X., Zhang Y. Hybrid anomaly detection in industrial energy consumption using Autoformer-based forecasting // Applied Energy. 2023. Vol. 315. P. 120821.
3. Steel Industry Data [Электронный ресурс] Режим доступа: <https://archive.ics.uci.edu/ml/datasets/Steel+Industry+Energy+Consumption> (Дата обращения 04.09.2025).
4. Хуснутдинов А. Кластеризация методом K-means. Теория и реализация. С нуля [Электронный ресурс] Режим доступа: <https://habr.com/ru/articles/868542/> (Дата обращения 12.09.2025).
5. Метрики качества линейных регрессионных моделей [Электронный ресурс] Режим доступа: <https://loginom.ru/blog/quality-metrics> (Дата обращения 12.09.2025).

УДК 004.891

ОБРАБОТКА ДОРЕФОРМЕННЫХ РУССКИХ ТЕКСТОВ: АНАЛИЗ ЭФФЕКТИВНОСТИ LLM ДЛЯ КОРРЕКЦИИ OCR-ОШИБОК НА ПРИМЕРЕ YANDEX VISION OCR И YANDEXGPT

Фитковская Я.А.¹ (студент)

Научный руководитель – редактор Издательства Уральского ГАУ Ерофеева А.В.²

¹МГУ им. М.В. Ломоносова

²Уральский государственный аграрный университет

fitkovskaya@yandex.ru

Аннотация

В статье исследуется применение больших языковых моделей – LLM (на примере YandexGPT) – для постобработки текстов, распознанных системами OCR (на примере Yandex Vision OCR) из дореформенных русских документов. На материале 50 исторических текстов показано снижение количества ошибок распознавания на 65–69 % в обработанном LLM тексте по сравнению с «сырыми» OCR-данными, из чего сделан вывод, что Yandex Vision имеет системные ошибки при работе с дореформенной орфографией и для данных целей требует дообучения на архаичных текстах, а постобработка LLM достаточно эффективно устраняет этот недостаток, хотя и LLM имеют свои слепые зоны.

Ключевые слова

Распознавание исторических источников, дореформенная орфография, Optical character recognition, исправление OCR, обработка естественного языка, постобработка текста.

Введение

Актуальность исследования обусловлена важностью задачи цифровизации исторических документов: интерес к генеалогии растет, поэтому для архивных систем важно качественно обрабатывать имеющиеся дореформенные документы, что трудно при нехватке специалистов, способных работать с дореволюционной орфографией [1]. При этом наблюдаются сложности и при использовании современных систем распознавания печатных и рукописных архаичных текстов: даже те из них, которые достигают точности 99% на современных текстах, оказываются недостаточно эффективными для обработки документов в дореформенной орфографии. Модификации OCR-архитектуры под лингвистическую специфику исторических текстов требуют значительных вычислительных ресурсов для дообучения лингвистических компонент [2]. Настоящее исследование предлагает альтернативный подход, основанный на применении языковых моделей большого размера для постобработки выходов стандартных OCR-систем. Целью исследования является оценка эффективности использования LLM в качестве универсального инструмента коррекции, не требующего реконфигурации базовых OCR-моделей. В области обработки исторических текстов применяются различные подходы к коррекции OCR-ошибок, включая методы нечетких множеств для восстановления тематической лексики [3] и специализированные нейросетевые архитектуры для реставрации поврежденных надписей [4]. Опыт исследований показывает, что ошибки распознавания оказывают каскадное влияние на последующие этапы текстового анализа [5]. Также имеются соображения о перспективности совместного использования автоматических методов и экспертной проверки для достижения максимальной точности [4]. В отличие от рассмотренных работ, настоящее исследование предлагает универсальный подход к коррекции OCR-ошибок в дореформенных русских текстах, не требующий составления тематических словарей или модификации архитектуры OCR-систем.

Методология

Материалы исследования

В исследовании использовался датасет Russian Old Orthography OCR [<https://huggingface.co/datasets/nevmenandr/russian-old-orthography-ocr>], содержащий сканы исторических документов XIX века и соответствующие им эталонные тексты. Датасет включает 50 пар «изображение – текст» с различными типами документов: архивные записи,

метрические книги, литературные произведения. Каждый документ представлен в двух форматах: отсканированное изображение в формате PNG и соответствующий ему текст в кодировке UTF-8 с сохранением оригинальной дореформенной орфографии.

Тексты датасета написаны в соответствии с орфографическими нормами, действовавшими до реформы 1917–1918 годов. Основные особенности включают:

- наличие букв, исключенных из современного алфавита: і (и десятеричное), ѣ (ять), ѿ (фита), ѡ (ижица);
- использование твердого знака (ъ) на конце слов после твердых согласных: домъ, столъ;
- специфические окончания прилагательных: -аго/-яго вместо -ого/-его (добраго, синяго);
- особенности правописания приставок и местоимений: безъ, разъ, съ; онаго, оныя;
- различие написаний «миръ» (вселенная) и «міръ» (отсутствие войны).

и некоторые другие особенности (полный список отличий от современной орфографии представлен во многих электронных источниках [6]).

Описание экспериментальной установки и процедура эксперимента

В исследовании использовалась двухэтапная pipeline-архитектура, включающая последовательную обработку документов системами Yandex Vision OCR и YandexGPT. На первом этапе изображения документов передавались в Yandex Vision API для автоматического распознавания текста. Полученный сырой текст, содержащий ошибки распознавания, направлялся на второй этап – коррекцию с помощью языковой модели YandexGPT.

Для обеспечения корректной обработки исторических текстов был разработан специализированный промпт, содержащий следующие компоненты:

- инструкция по сохранению дореформенной орфографии с запретом на модернизацию текста;
- подробное описание правил дореформенной орфографии с примерами;
- списки исторических букв и их корректного употребления (ять, фита, и десятеричное);
- примеры типичных ошибок распознавания и ожидаемых исправлений;
- указание на источник ошибок (OCR-распознавание рукописных текстов);
- четкое разграничение между ошибками распознавания и историческими орфографическими нормами.

Промпт был сконструирован таким образом, чтобы модель исправляла исключительно ошибки, внесенные системой OCR, сохраняя при этом все особенности исторической орфографии.

Для количественной оценки эффективности предложенного метода использовались следующие метрики:

Character Error Rate (CER) – метрика, измеряющая отношение количества ошибочных символов к общему количеству символов в эталонном тексте. Вычисляется по формуле:

$$CER = \frac{(S + D + I)}{N},$$

где S – замены; D – удаления; I – вставки; N – общее количество символов.

Word Error Rate (WER) – метрика, оценивающая точность на уровне слов. Рассчитывается так:

$$WER = \frac{(S_w + D_w + I_w)}{N_w},$$

где S_w – замены слов; D_w – удаления слов; I_w – вставки слов; N_w – общее количество слов.

Improvement Rate – относительное улучшение качества после коррекции:

$$\text{Improvement} = \frac{(\text{Metric}_{\text{raw}} - \text{Metric}_{\text{corrected}})}{\text{Metric}_{\text{raw}}} \times 100\%.$$

Все метрики вычислялись путем попарного сравнения трех версий текстов: эталонной (ground truth), «сырой» OCR и исправленной LLM.

Результаты

Общая эффективность коррекции

Эксперимент, проведенный на 50 исторических документах, показал значительное улучшение качества текстов после LLM-коррекции. Сравнение метрик до и после обработки выявило следующее (таблица).

Таблица

Сравнение качеств метрик до и после коррекции

Метрика	До коррекции, %	После коррекции, %	Улучшение, %
CER (средний)	13,66	4,28	68,7
WER (средний)	33,03	11,51	65,2

Из этих данных можно сделать общий вывод, что применение LLM-коррекции позволило снизить количество ошибок на уровне символов на 68,7%, а на уровне слов – на 65,2%. Стандартное отклонение улучшения CER составило 2,52%, что свидетельствует о стабильности результатов на всем датасете.

Анализ паттернов ошибок OCR

Детальный анализ сырых выходов Yandex Vision OCR выявил системные паттерны ошибок, характерные для распознавания текстов в дореформенной орфографии:

- невозможность распознавания буквы Ъ – Yandex Vision в таких случаях помечал ее тегом <unk> (196 случаев);
- путаница Ъ и ъ (36 случаев);
- замена ъ на ь (11 случаев).

Анализ указывает на то, что Yandex Vision OCR не знаком с дореволюционной орфографией и без постобработки не может использоваться для оцифровки исторических печатных документов, хотя точность на буквах современного русского или латинского (в частности, *i*) алфавитов достигает 98% (вывод сделан из анализа ошибок распознавания букв современного русского алфавита).

При анализе паттернов ошибок была обнаружена интересная закономерность: значительное количество замен Ъ → е и Ъ → ё, которые не могут быть объяснены визуальным сходством символов. Данные замены, однако, полностью соответствуют историческим фонетическим преобразованиям, отраженным в орфографии после орфографической реформы 1917–1918 годов. Обнаруженные лингвистически мотивированные замены позволяют предположить, что в пайплайне Yandex Vision могут присутствовать компоненты, осуществляющие нормализацию текста. Однако для верификации этой гипотезы требуются дополнительные исследования архитектуры системы.

Эффективность LLM-коррекции

После применения LLM-коррекции наблюдались следующие изменения в структуре ошибок.

Наиболее успешно исправляемые ошибки:

- восстановление исторических букв (ять, фита);
- устранение артефактов распознавания, таких как несвоевременные переносы строк, разрывы слова пробелом или дефисом и т. д.;
- устранение артефактов распознавания, таких как мена букв ь//ъ, н//п и прочих.

Сохраняющиеся проблемы:

- частичная путаница исторических символов (24 случая Ъ → е);
- регистровые ошибки и опечатки в похожих символах;
- устранялись не все артефакты распознавания букв современного русского алфавита.

Приведем примеры распознавания и коррекции.

Пример 1:

OCR: Обстоятельство дневки давало мн% много свободного времени, и я рассу-дила употребить его на то, чтобъ уз-нать подробн <unk>е о Гудишкахъ

LLM: Обстоятельство дневки давало мнѣ много свободного времени, и я разсудила употребить его на то, чтобъ узнать подробнѣе о Гудишкахъ

Эталон: Обстоятельство дневки давало мнѣ много свободного времени, и я разсудила употребить его на то, чтобъ узнать подробнѣе о Гудишкахъ

Модель успешно исправила % → ъ, <unk> → ъ и склеила перенесенные слова **разсудила** → **разсудила**, **уз-нать** → **узнать**.

Пример 2:

OCR: въ ваши лѣта очень лестень и этотъ крестъ и этотъ нарядъ

LLM: въ ваши лѣта очень лестень и этотъ крестъ и этотъ нарядъ

Эталон: въ ваши лѣта очень лестень и этотъ крестъ и этотъ нарядъ

Модель исправила **лѣта** → **лѣта**, но сохранила все твердые знаки и исторические формы.

Пример 3:

OCR: плутала ц <unk>лую ночь и о кото-рыхъ жидь-Арендаторъ рассказывалъ такую страницу

LLM: плуталъ цѣлую ночь и о которыхъ жидь-Арендаторъ рассказывалъ такую страницу

Эталон: плуталъ цѣлую ночь и о которыхъ жидь-Арендаторъ рассказывалъ такую страницу

Модель исправила <unk> → ъ, склеила **кото-рыхъ** → **которыхъ**, поправила род глагола **плутала** → **плуталъ**.

Анализ 50 документов показал:

- восстановление ъ из различных OCR-артефактов: 42% случаев;
- исправление переносов и склейка слов: 28% случаев;
- коррекция опечаток в именах собственных: 15% случаев;
- восстановление исторических окончаний: 10% случаев;
- прочие исправления: 5% случаев.

Обсуждение

Полученные результаты демонстрируют высокую эффективность LLM в задаче коррекции OCR-ошибок при работе с дореформенными текстами. Улучшение метрик CER на 68,7% и WER на 65,2% свидетельствует о том, что языковые модели способны не только распознавать паттерны ошибок, но и восстанавливать исторический контекст, что особенно важно при работе с архаичной орфографией. Предложенный подход имеет практическую ценность для архивов и исследователей, работающих с историческими документами, при этом использование LLM позволяет использовать существующие OCR-системы без их модификации.

Несмотря на высокую эффективность, метод имеет ряд ограничений, устранение которых представляет перспективные направления для будущих исследований:

1. Тонкая настройка промптов с учетом специфики различных типов исторических документов (метрические книги, газеты, письма) может значительно повысить точность коррекции.
2. Разработка специализированных модулей для коррекции ошибок форматирования (переносы строк, абзацы) могла бы устранить одно из основных ограничений текущего подхода.
3. Внедрение механизмов контекстного анализа позволило бы улучшить исправление имен собственных и терминов, которые слабо представлены в тренировочных данных LLM.

Дальнейшее развитие метода может включать создание специализированных интерфейсов для архивных работников, разработку доменно-специфичных промптов для различных исторических периодов и интеграцию с системами верификации экспертов.

Заключение

Проведенное исследование продемонстрировало высокую эффективность применения языковых моделей большого размера (LLM) для коррекции OCR-ошибок в дореформенных

русских текстах. Рассмотренная двухэтапная методика, сочетающая распознавание Yandex Vision с последующей LLM-коррекцией, позволила достичь снижения ошибок на уровне символов на 68,7% (CER) и на уровне слов на 65,2% (WER).

Ключевым достижением работы является разработка системы промптов, обеспечивающей сохранение исторической орфографии при исправлении ошибок распознавания, а также построение таблицы метрик с последующей оценкой эффективности использования LLM в задаче постобработки распознанных исторических документов. Модель успешно справляется с восстановлением архаичных символов (ять, фита, и десятичное), коррекцией контекстных ошибок и сохранением исторических грамматических форм.

Перспективными направлениями дальнейших исследований являются разработка доменно-специфичных промптов для различных типов исторических документов, создание модулей коррекции форматирования и внедрение систем многоуровневой валидации.

Литература

1. Мирошниченко М.А., Шевченко Ю.В., Охрименко Р.С. Сохранение исторического наследия государственных архивов путем оцифровки архивных документов // Вестник Академии знаний. 2020. № 2 (37). С. 188–194.
2. Поврозник Н.Г., Исмакаева И.Д. Дискуссии в губернских земствах в отражении текстовых карт: от визуализации к анализу // Вестник Пермского университета. 2019. Вып. 3 (46). С. 146–158.
3. Галушко И.Н. Корректировка результатов OCR-распознавания текста исторического источника с помощью нечетких множеств (на примере газеты начала XX века) // Историческая информатика. 2023. № 1. DOI: 10.7256/2585-7797.2023.1.40387.
4. Assael Y., Sommerschield T., Shillingford B. et al. Restoring and attributing ancient texts using deep neural networks // Nature. 2022. Vol. 603. Pp. 280–283. DOI: 10.1038/s41586-022-04448-z.
5. Lopresti D. Optical character recognition errors and their effects on natural language processing // IJDAR. 2009. Vol. 12. Pp. 141–151. DOI: 10.1007/s10032-009-0094-8.
6. Русская дореформенная орфография [Электронный ресурс] Режим доступа: https://ru.wikipedia.org/wiki/Русская_дореформенная_орфография (Дата обращения 10.10.2025).

ЭКОНОМИКА, ФИНАНСЫ И УСТОЙЧИВОЕ РАЗВИТИЕ

УДК 331.56

АНАЛИЗ УРОВНЯ БЕЗРАБОТИЦЫ В РОССИИ В ПОСТПАНДЕМИЙНЫЙ ПЕРИОД

Половинкин В.В.¹ (магистрант), Соложенкина Е.Е.¹ (магистрант)
Научный руководитель – доктор социологических наук Половинкин В.А.¹
¹Университет ИТМО
valerypolovinkin@gmail.com

Аннотация

В статье анализируются причины и последствия снижения уровня безработицы в России до исторического минимума в 2024 году. На основе данных Росстата, нормативных документов и экспертных оценок рассматриваются ключевые факторы, повлиявшие на динамику занятости в постпандемийный период. Показано, что после кратковременного роста безработицы в 2020 году её уровень последовательно снижался, достигнув минимальных значений к 2024 году. Основными детерминантами данного процесса стали повышение пенсионного возраста, включение мобилизованных и добровольцев в категорию занятых, а также структурные преобразования экономики, сопровождаемые ростом внутреннего спроса на труд. При этом эмиграция и релокация населения не оказали существенного влияния на сокращение безработицы. Отмечено, что снижение показателя сопровождалось усилением кадрового дефицита и дисбалансом между спросом и предложением рабочей силы. Сделан вывод о необходимости реализации комплексных мер, направленных на повышение производительности труда, развитие системы профессиональной переподготовки и стимулирование региональной мобильности работников. Полученные результаты могут быть использованы при формировании государственной политики занятости и стратегий развития рынка труда.

Ключевые слова

Рынок труда, уровень безработицы, занятые, безработные, рабочая сила.

Современный рынок труда России переживает серьёзные структурные изменения под влиянием экономических преобразований и внешних вызовов. Зачастую снижение безработицы воспринимается как положительный сигнал, однако в настоящее время оно сопровождается дефицитом кадров и ускоренным ростом заработных плат, что создаёт риски для устойчивого развития экономики страны. Ранее исследователи анализировали влияние отдельных факторов на занятость, но их совокупное воздействие остаётся недостаточно изученным.

Уровень безработицы в России в апреле 2024 года достиг нового исторического минимума в 2,6%, следует из ежемесячного доклада Росстата [7]. Это минимальное значение за последние десятилетия, что подтверждает структурные сдвиги в экономике. Подобная динамика характерна для периода восстановления после шоковых кризисов. «Уровень безработицы в три процента для России – это аномально, и это точно тормоз для развития экономики. Это выражается в опережающем росте зарплат, что в целом неплохо, если бы не дефицит кадров, дефицит специалистов — и количественный, и качественный», — сказал в сентябре 2023 года глава Минэкономразвития Максим Решетников [4].

Согласно учебной литературе, безработица – это макроэкономическое явление, суть которого состоит в том, что трудоспособное население не может найти работу с целью заработка денег и обеспечения своей жизни [1]. Безработными считаются люди, которые не имеют работы и дохода, а также зарегистрированы в органах службы занятости и находятся в активном поиске работы.

Согласно классификации МОТ (международной организации труда), люди являются безработными если соответствуют следующим критериям:

1. Возраст старше 15 лет.
2. Не имеют работы или источника дохода.

3. В последние 4 недели искали работу, используя различные методы поиска.

Студенты, инвалиды и пенсионеры также относятся к безработным, если они не заняты на работе, активно её ищут и готовы к ней приступить. Рабочей силой называют людей от 15 лет и старше, которые в рассматриваемый период считаются занятыми или безработными.

Показатель уровня безработицы определяется как доля безработных в общей численности рабочей силы (в процентах) [9].

В последние годы в России наблюдается устойчивая тенденция к снижению уровня безработицы. После временного всплеска безработицы в 2020 году, вызванного пандемией COVID-19, показатель сократился с 5,8% в 2020 году до 3,2% к 2023 году и продолжил уменьшаться, достигнув исторического минимума 2,5% в 2024 году (рис. 1). Снижение безработицы отражает перемены на рынке труда, не все из которых можно назвать благоприятными.




Рис. 1. Уровень безработицы в РФ в 2017–2024 гг, %

Для оценки темпов снижения уровня безработицы за период 2020–2024 гг. воспользуемся формулой относительного изменения показателя:

$$I = \frac{U_{2024}}{U_{2020}} * 100\%, \quad (1)$$

где I — индекс изменения уровня безработицы в процентах, U_{2024} — уровень безработицы в 2024 году в процентах, U_{2020} — уровень безработицы в 2020 году в процентах.

$$I = \frac{2,5}{5,8} * 100\% = 43,1\%.$$

Таким образом, уровень безработицы в 2024 году составил 43,1% от уровня 2020 года, то есть снизился почти на 57%. На снижение уровня безработицы, вероятно, оказали влияние следующие ключевые факторы:

- эмиграция/релокация;
- мобилизация;
- пенсионная реформа.

Как видно из рисунка 2, в 2021–2024 годах число людей, прибывших в Россию, стабильно превышало число выбывших из страны. Таким образом, сальдо миграции оставалось положительным, и эмиграция не оказала существенного влияния на сокращение безработицы в РФ. Например, в 2022 году десятки тысяч россиян временно релоцировались за границу, однако впоследствии многие вернулись обратно, вновь пополнив состав рабочей силы. В

2024 году миграционный прирост достиг рекордных 568,5 тыс. человек, что подтверждает, что отток населения не являлся решающим фактором в динамике безработицы.




Рис. 2. Количество выбывших и прибывших в РФ за 2021–2024 гг, чел.

В 2022 году в России была введена частичная мобилизация. Согласно «Коммерсанту» [5], за 2 года число мобилизованных превысило 300 тыс. человек. Всего за 2023 год в рамках кампании по набору добровольцев набрано 486 тыс. человек. Военнослужащие, включая мобилизованных, относятся к категории занятых [3], соответственно, они пополняют рабочую силу. Из этого следует, что мобилизация также не может быть объяснением снижения уровня безработицы.

В январе 2019 года в России стартовала пенсионная реформа, предполагающая поэтапное повышение пенсионного возраста. Ранее женщины становились пенсионерами в 55 лет, а мужчины в 60 лет; теперь же ежегодно возраст выхода на пенсию увеличивается, и в итоге пенсионный возраст повысится на пять лет [6]. Проведение пенсионной реформы повлияло на ситуацию на рынке труда: эксперты полагали, что в 2019 году около миллиона человек, которые по старым правилам могли бы уже выйти на пенсию, останутся на рынке труда [2]. Это обстоятельство стало одной из причин статистического снижения уровня безработицы, который наблюдался в последующие годы.

Надо отметить, что рекордно низкий уровень безработицы сопровождается и определенными проблемами на рынке труда. Одним из показателей дисбаланса служит разница между численностью безработных и количеством заявленных работодателями вакансий. На 2024 год разница между числом безработных и количеством вакансий достигла рекордного значения — 2,2 млн человек. Для сравнения, в конце 2022 года, когда рынок труда уже был напряженным, показатель превышал 1 млн человек. Увеличение разрыва указывает на всё более значительный дефицит кадров на рынке труда, что создает давление на зарплаты и сдерживает развитие экономики.

Несмотря на рекордно низкую безработицу в РФ, в отдельных отраслях наблюдается высокий дефицит кадров. Например, в 2024 году в судостроительной отрасли по сравнению с 2022 годом спрос на сотрудников вырос на 155% [8]. Таким образом, даже при низком уровне безработицы наблюдается структурная несбалансированность рынка труда, при которой количество свободных вакансий значительно превышает число специалистов, способных их занять.

Для смягчения негативных последствий безработицы можно предложить следующие меры:

1. Улучшение системы профессиональной переподготовки в отраслях с наибольшим дефицитом кадров. Данная мера позволит повысить квалификацию работников и сокращать разрыв между спросом и предложением рабочей силы. Ожидаемым результатом можно считать уменьшение количества незакрытых вакансий.
2. Стимулирование территориальной мобильности работников. Предполагается, что такая политика позволит компенсировать локальные кадровые дефициты.
3. Повышение производительности труда за счет цифровизации производства. Данный пункт должен реализоваться с прицелом на долгосрочную перспективу – автоматизация позволит снизить зависимость отраслей от дефицита специалистов.
4. Государственные меры поддержки, направленные на удержание сотрудников и создание условий для долгосрочной занятости. Такими мерами являются программы карьерного роста, льготы и социальные гарантии для сотрудников. Их реализация позволяет работодателям планировать развитие без постоянного дефицита специалистов.
5. Адаптация системы образования к реальным потребностям рынка труда. Необходимо учитывать демографические особенности современных реалий и повышать долю молодых квалифицированных работников.

Реализация предложенных мер способна снизить дисбаланс между спросом и предложением рабочей силы и повысить устойчивость занятости в России.

Проведённый анализ показал, что уровень безработицы в России продолжает снижаться после временного роста, обусловленного пандемией COVID-19, что свидетельствует о положительных тенденциях на рынке труда и эффективности ряда принятых мер государственной политики в сфере занятости.

Вместе с тем на рынке труда сохраняется дисбаланс между предложением рабочей силы и спросом на неё. Наличие значительной доли безработных и граждан, находящихся в поиске работы, указывает на необходимость дальнейших усилий по созданию новых рабочих мест и реализации программ поддержки занятости.

Литература

1. Анисимов А.А. Макроэкономика. Теория, практика, безопасность: учеб. пособие для студентов вузов, обучающихся по экономическим специальностям / А.А. Анисимов, Н.В. Артемьев, О.Б. Тихонова; под ред. Е.Н. Барикаева. – М.: ЮНИТИ-ДАНА, 2015. 599 с.
2. Безработица и низкий доход. Как пенсионная реформа скажется на экономике [Электронный ресурс] Режим доступа: <https://www.forbes.ru/finansy-i-investicii/364407-bezrabotica-i-nizkiy-dohod-kak-pensionnaya-reforma-skazhetsya-na> (Дата обращения: 10.10.2025).
3. Информация Федеральной службы государственной статистики от 5 октября 2022 г. «Росстат разъясняет особенности учета занятости добровольцев и мобилизованных работников» [Электронный ресурс] Режим доступа: <https://base.garant.ru/405386299/> (Дата обращения: 10.10.2025).
4. Министр экономического развития назвал минусы низкой безработицы [Электронный ресурс] Режим доступа: <https://aoczn.ru/2023/09/06/ministr-ekonomicheskogo-razvitiya-nazval-minusy-nizkoj-bezraboticy/> (Дата обращения: 12.10.2025).
5. Минобороны раскрыло точное число мобилизованных россиян [Электронный ресурс] Режим доступа: <https://www.kommersant.ru/doc/6427669> (Дата обращения: 15.10.2025).
6. Пенсионный возраст в России: кто и когда выходит на пенсию [Электронный ресурс] Режим доступа: <https://journal.sovcombank.ru/sberezheniya/pensionnii-vozrast-v-rossii-kto-i-kogda-vihodit-na-pensiyu> (Дата обращения: 22.10.2025).
7. Социально-экономическое положение России [Электронный ресурс] Режим доступа: <https://rosstat.gov.ru/storage/mediabank/osn-04-2024.pdf> (дата обращения: 13.10.2025).
8. Судостроение: топ фактов об отрасли по итогам семи месяцев 2024 года [Электронный ресурс] Режим доступа: <https://spb.hh.ru/article/sudostroenie-top-faktov-ob-otrasli-po-itogam-semimesyacev-2024-goda> (Дата обращения: 29.10.2025).
9. Уровень безработицы [Электронный ресурс] Режим доступа: <https://www.fedstat.ru/indicator/43062> (Дата обращения: 10.10.2025).

УДК 336.647

ПРИМЕНЕНИЕ И ОЦЕНКА КОНЦЕПЦИИ СРЕДНЕВЗВЕШЕННОЙ СТОИМОСТИ КАПИТАЛА (WACC) ДЛЯ ФИНАНСИРОВАНИЯ ДЕЯТЕЛЬНОСТИ ПРОМЫШЛЕННОГО ПРЕДПРИЯТИЯ НА ПРИМЕРЕ ПАО «СЕВЕРСТАЛЬ»

Половинкин В.В.¹ (магистрант), Соложенкина Е.Е.¹ (магистрант)
Научный руководитель – доктор социологических наук Половинкин В.А.¹

¹Университет ИТМО
valerypolovinkin@gmail.com

Аннотация

В статье анализируется экономическая сущность концепции средневзвешенной стоимости капитала (WACC) и её применение в финансировании деятельности промышленных предприятий. Рассматривается структура капитала, распределение собственного и заемного финансирования, а также роль WACC в принятии инвестиционных и финансовых решений. Особое внимание уделяется достоинствам концепции, таким как возможность учета различных источников капитала, оценка минимально необходимой доходности для инвесторов и упрощение процесса принятия инвестиционных решений. Одновременно исследуются недостатки WACC, в том числе субъективность определения составляющих показателя, изменчивость рыночных условий и трудности с получением достоверных данных для расчетов. На примере ПАО «Северсталь» продемонстрировано практическое применение WACC для расчета удельных весов собственного и заемного капитала, эффективной ставки налога и определения минимально необходимой доходности на совокупный капитал. Показано, что корректное использование WACC позволяет оптимизировать финансовую стратегию предприятия, сбалансировать доходность и риск, а также повысить инвестиционную привлекательность компании. Несмотря на определенные ограничения, WACC остается ключевым инструментом корпоративного финансового управления и оценки стоимости капитала.

Ключевые слова

Средневзвешенная стоимость капитала, WACC, структура капитала, финансовый менеджмент.

В современных условиях эффективность финансового управления является критически важной для промышленных предприятий. Традиционные подходы к оценке структуры капитала, основанные преимущественно на соотношении собственного и заемного финансирования или на нормативных ставках доходности, зачастую не отражают реальную стоимость разных источников капитала и связанные с ними риски. В результате инвесторы могут принимать неоптимальные инвестиционные решения, что негативно сказывается на финансовой устойчивости предприятия. Концепция средневзвешенной стоимости капитала (WACC) позволяет интегрировать различные источники финансирования с учетом их удельного веса, стоимости капитала и налоговых обязательств. Применение WACC обеспечивает возможность оценки минимально необходимого уровня доходности и упрощает принятие финансовых решений, что делает данный подход более точным и комплексным по сравнению с традиционными методами.

Структура капитала предприятия представляет собой распределение собственных и заемных источников финансирования и служит важным показателем его финансовой устойчивости. Эффективное управление структурой капитала является одной из ключевых задач финансового менеджмента, поскольку определяет способность компании поддерживать баланс между ликвидностью, платежеспособностью и инвестиционной привлекательностью. Оптимизация структуры капитала позволяет классифицировать источники финансирования по стоимости и приоритетности, минимизировать затраты на обслуживание долговых обязательств и повышать рыночную стоимость предприятия [2].

Успешное инвестирование в промышленные предприятия предполагает постоянную работу по анализу и оценке эффективности показателей его деятельности. Зачастую инвестору приходится принимать решение о выборе одного проекта из нескольких альтернативных. В большинстве случаев наиболее выгодным выбором станет проект с максимальной доходностью и приемлемым уровнем риска. Таким образом, инвесторам выгодно использовать

WACC как индикатор целесообразности инвестиций. Показатель WACC (Weighted Average Cost of Capital) был предложен экономистами Ф. Модильяни и М. Миллером в 1958 году. Его экономический смысл заключается в том, что если рентабельность компании как минимум достигает текущего значения WACC, то инвестировать средства в такую компанию выгодно. К примеру, когда рентабельность бизнеса составляет 23%, а средневзвешенная стоимость капитала около 12%, фактически каждый вложенный рубль приносит порядка 11% прибыли. Соответственно, когда доходность фирмы не дотягивает до уровня WACC, вкладывать дополнительные инвестиции не имеет смысла, поскольку прибыльность не покрывает стоимость привлеченного капитала. Напротив, если доходность существенно выше WACC, предприятие создаёт дополнительную ценность и обеспечивает инвесторам экономическую прибыль. В результате привлечения различных видов капитала складывается определенная структура капитала и формируется определенная сумма финансовых ресурсов, которую необходимо уплатить за пользование данными источниками финансирования [1].

Показатель WACC указывает, насколько дорого компании обходится привлекаемый капитал. Формула для расчета WACC:

$$WACC = w_e R_e + w_d R_d (1 - t), \quad (1)$$

где R_e – требуемая собственниками доходность, R_d – требуемая кредиторами доходность, w_e – удельный вес собственного капитала в совокупном капитале, w_d – удельный вес заемного капитала в совокупном капитале, t – ставка налога на прибыль.

Ставка налога на прибыль рассчитывается по формуле:

$$\text{Эффективная ставка} = \frac{\text{Налог на прибыль}}{\text{Прибыль до налогообложения}} * 100\%, \quad (2)$$

WACC, или средневзвешенная стоимость капитала, обладает несколькими важными достоинствами:

1. Учет всех источников финансирования и их веса. Методика WACC учитывает как собственный, так и заемный капитал компании, присваивая каждому источнику соответствующий удельный вес. Такой подход обеспечивает более точный расчет средней стоимости капитала организации с учётом относительного влияния каждого из источников.
2. Определение минимальной требуемой доходности для инвесторов. С помощью WACC можно определить минимально необходимый уровень доходности, при котором инвестиции считаются оправданными. Если ожидаемая рентабельность проекта ниже WACC, проект будет убыточным для владельцев капитала. Сравнение ожидаемой доходности инвестиционных проектов со значением WACC позволяет отобрать наиболее эффективные вложения и тем самым оптимизировать структуру капитала компании.
3. Единый показатель для упрощения финансовых решений. WACC выступает единым интегрированным показателем, объединяющим информацию о стоимости всех источников капитала с учетом налогового вычета. Наличие такой универсальной метрики упрощает сравнение и ранжирование проектов по уровню доходности и риска.

В итоге применение WACC значительно облегчает процесс принятия инвестиционных решений. Опираясь на данный показатель, компания может уверенно отбирать наиболее прибыльные проекты и выстраивать оптимальную структуру капитала. Всё это в совокупности способствует более эффективному управлению финансами предприятия. Ко всему прочему, ориентация на WACC делает финансовую политику компании более понятной для инвесторов, повышая доверие к принимаемым решениям.

Однако, несмотря на широкое распространение, метод WACC не лишён слабых мест. Среди недостатков WACC экономисты выделяют:

1. Субъективность оценки компонентов WACC. Расчет требует определения стоимости собственного и заемного капитала, а также структуры капитала. Эти параметры могут основываться на суждениях и предположениях, что снижает точность расчета.

2. Зависимость от рыночных факторов. Изменения процентных ставок, структуры рынка и инвестиционных условий могут повлиять на стоимость капитала и, соответственно, на WACC, что требует периодического пересмотра и обновления расчетов.
3. Сложность определения налоговой ставки. В финансовой практике различают эффективную и маржинальную ставки налога на прибыль. Эффективная ставка отражает фактический уровень налоговых обязательств с учётом корректировок и вычетов, а маржинальная показывает налог на каждый дополнительный рубль прибыли и обычно соответствует законодательной ставке. Универсального правила выбора ставки для расчета WACC нет, но чаще ориентируются на значение, минимизирующее налоговую нагрузку и отражающее реальную стоимость капитала [3].

4. Трудности с получением достоверных данных. Проблема возникает при учете различных источников финансирования и их пропорций, а также при отсутствии полной отчетности.

Несмотря на недостатки, концепция WACC все равно является широко используемым инструментом для оценки стоимости капитала предприятия. Однако при использовании WACC следует соблюдать осторожность и принимать во внимание указанные недостатки, чтобы минимизировать ошибки и достичь более точной оценки стоимости капитала.

Северсталь — промышленное предприятие полного металлургического цикла, специализирующееся на выпуске листового и сортового проката и стальных труб черных металлов широкого сортамента, а также метизной и штамповочной продукции. По объему производства Северсталь является второй после НЛМК вертикально интегрированной горнодобывающей и металлургической компанией в России. На долю компании приходится около 16,5% объема выпуска стали в стране [5].

Для определения удельных весов собственного и заемного капитала воспользуемся формой финансовой отчетности «Отчет о финансовом положении» [4].

Совокупный капитал компании рассчитывается по формуле:

$$V = E + D, \quad (3)$$

где E — собственный капитал, D — заемный капитал

Совокупный капитал на 2020 году в ПАО «Северсталь» составил:

$$E + D = 2\,744 + 2\,002 = 4\,746 \text{ млн. долл.}$$

Удельный вес собственного капитала рассчитывается по формуле:

$$W_e = \frac{E}{(D+E)}, \quad (4)$$

где W_e — удельный вес собственного капитала.

$$W_e = \frac{2\,744}{4\,746} = 0,57 = 57\%.$$

Удельный вес заемного капитала рассчитывается по формуле:

$$W_d = \frac{D}{(D+E)}, \quad (5)$$

где W_d — удельный вес заемного капитала.

$$W_d = \frac{2\,002}{4\,746} = 0,43 = 43\%.$$

Рассчитаем эффективную ставку налогообложения по таблице 1.

Таблица 1

Расчёт ставки налогообложения (tax rate)

Период	Прибыль до налогообложения, млн. дол.	Налог на прибыль, млн. дол.	Эффективная ставка, %
2019	2 232	465	20.8%
2020	1 309	293	22.3%
Среднеарифметическое значение (Tax rate)			21.6%

В таблице 2 указаны данные для определения WACC.

Таблица 2

Данные для расчета WACC ПАО «Северсталь»

R_e	14.21
R_d	4.23
W_e	0.58
W_d	0.42
Ставка налогообложения	21.6%

Имея все необходимые значения для расчета, можно определить средневзвешенную стоимость совокупного капитала компании:

$$WACC = 0.58 * 14.21 + 0.42 * 4.23\% * (1 - 0.218) = 9.63\%.$$

Поскольку WACC используется инвесторами как минимальный пороговый уровень доходности, можно сделать следующий вывод: ПАО «Северсталь» необходимо иметь доходность на совокупный капитал не менее 9,63%, чтобы быть привлекательной компанией для инвесторов.

Таким образом, изучение концепции средневзвешенных затрат на капитал подтверждает ее актуальность для финансирования деятельности промышленных предприятий. Грамотное использование WACC позволяет предприятиям точнее оценивать стоимость капитала, принимать более обоснованные финансовые решения и привлекать инвестиции. Актуальность данной концепции обусловлена необходимостью оптимального финансирования, обеспечения надлежащего уровня доходности и управления рисками. Несмотря на некоторые ограничения и сложности в определении компонентов WACC, его применение остается важным и полезным при принятии инвестиционных решений и оценке стоимости компаний. Глубокое понимание концепции WACC является необходимостью для предприятий, стремящихся эффективно управлять своим финансированием и достичь конкурентных преимуществ при привлечении инвестиций. Однако следует отметить, что использование WACC требует анализа и учета контекста каждой конкретной ситуации.

Литература

1. Киршин И.А. Стратегический финансовый менеджмент: учебное пособие. – Казань: Казан. ун-т, 2019. С. 6.
2. Гравель К.Ю. Исследование влияния структуры капитала на финансовое состояние предприятия. – Екатеринбург, 2019. 112 с.
3. Средневзвешенная стоимость капитала, WACC [Электронный ресурс] Режим доступа: <https://www.alt-invest.ru/lib/wacc/> (Дата обращения 28.10.2025).
4. Финансовая отчетность ПАО «Северсталь» за 2020 год [Электронный ресурс] // Северсталь. – Режим доступа: <https://severstal.com/rus/ir/indicators-reporting/finreps-rsbu/> (дата обращения: 28.10.2025).
5. Обзор Северсталь: один из лидеров отечественной металлургии [Электронный ресурс] Режим доступа: <https://gazprombank.investments/blog/reviews/severstal/> (Дата обращения 28.10.2025).

УДК: 658.567.1

СРАВНИТЕЛЬНЫЙ АНАЛИЗ ОРГАНИЗАЦИЙ В РФ ПО ПЕРЕРАБОТКЕ ПЛАСТИКА

Стрельцова Я.А.¹ (магистрант), Усов Е.С.¹ (магистрант)

¹Университет ИТМО

yaroslavastreltsova@yandex.ru; wertigo157@mail.ru

Аннотация

Исследование посвящено аналитическому изучению современного состояния и тенденций развития отрасли переработки пластиковых отходов в Российской Федерации, а также оценке её вклада в формирование устойчивой экологической и экономической системы. В работе рассматриваются ключевые закономерности и динамика развития полимерного сектора, структура перерабатывающих предприятий. Обобщены виды пластиков, перерабатываемых на российском рынке (ПЭТ, ПНД, ПВД, ПП и др.), и приведена сравнительная характеристика крупнейших предприятий, таких как «ЭкоЛайн-ВторПласт», «РТ-Инвест» и «TotalCycle», с анализом их объёмов переработки и продукции (гранулы, пленка, упаковка). Цель состоит в проведении сравнительного анализа организаций, занимающихся утилизацией пластиковых отходов. Также, внимание уделяется анализу формированию внутреннего рынка вторичных полимеров и перспективам его роста. Методологическая основа исследования основана на системном и сравнительном подходах с использованием табличных и графических методов визуализации, что обеспечивает комплексный аналитический характер работы. На базе статистических и отраслевых данных установлены положительные тенденции увеличения числа предприятий, расширения мощностей по выпуску вторичных полимеров и укрепления технологического потенциала отрасли.

Ключевые слова

Переработка пластика, пластиковые отходы, экономика замкнутого цикла, утилизация, Российская Федерация, сравнительный анализ, управление отходами, вторичное сырьё.

Введение

Загрязнение окружающей среды на нашей планете является одной из самых насущных угроз для большинства форм жизни, и пластиковые отходы играют в этом процессе ключевую роль. Современный образ жизни немыслим без использования пластика, обладающего такими свойствами, как долговечность, малый вес и хорошие барьерные качества, что делает его экономически выгодной альтернативой другим материалам. Однако именно долговечность пластика оборачивается сокрушительным вредом для окружающей среды, поскольку большая его часть оказывается на свалках, где разлагается столетиями, выделяя вредные вещества, и приводит к образованию микропластика, который, как показывают недавние исследования, уже обнаруживается в крови человека. Проблема усугубляется и тем, что накопление отходов в природе, как отмечает Международная некоммерческая организация Pure Earth, имеет разрушительные последствия для здоровья человека, о чем свидетельствует показатель DALY, отражающий снижение продолжительности жизни от негативного воздействия промышленности [1].

С учётом нарастающего негативного воздействия пластиковых отходов на здоровье населения и экосистемы, особую практическую значимость приобретает анализ национальных стратегий обращения с пластиками и оценка результативности реализуемых мер в условиях Российской Федерации [2]. Такой анализ необходим для адаптации международного опыта и формирования модельных решений, способствующих переходу к принципам устойчивого развития.

Осознавая остроту проблемы, государство предпринимает шаги по её решению. "Мусорная реформа", стартовавшая в 2019 году, инициировала важные изменения, направленные на снижение объёмов полигонного захоронения и увеличение переработки вторсырья. Национальный проект «Экология», запущенный после «майских» указов президента России в 2018 году, поставил амбициозную цель - повысить процент утилизации ТКО до 36% к 2024 году и обеспечить 100% сортировку всех отходов к 2030 году. Эти

инициативы соответствуют концепции экономики замкнутого цикла, активно развиваемой в Европейском союзе, где уже планируются многомиллиардные инвестиции в химическую переработку [3].

Согласно данным Союза переработчиков пластмасс, в 2023 году в Российской Федерации было зарегистрировано 2354 новых юридических лица с основным видом деятельности «производство пластмассовых и резиновых изделий», что на 20,3% превышает показатель предыдущего года. В результате совокупное количество действующих перерабатывающих предприятий впервые за последние годы продемонстрировало положительную динамику: наряду с регистрацией новых участников рынка прекратили деятельность 1624 организации, что на 13,8% меньше, чем в 2022 году. Таким образом, отрасль получила чистый прирост около 730 компаний, что свидетельствует о стабилизации сектора после периода спадов и об усилении предпринимательской активности в сфере переработки полимеров [4].

Структура российского полимерного бизнеса продолжает сохранять выраженную фрагментированность: на микропредприятия с годовым оборотом менее 120 млн руб. приходится порядка 77% отрасли, на малые предприятия (от 120 до 900 млн руб.) – около 19%, на средние компании (900–2000 млн руб.) – 3%, и лишь 1% совокупного числа участников составляют крупные производственные структуры с оборотом свыше 2 млрд руб. Такая диспропорция указывает на ограниченные возможности технологического обновления малых переработчиков и низкий уровень концентрации капитала в отрасли [4].

При общем росте институционального и производственного потенциала отрасль переработки пластмасс сталкивается с системными вызовами, тормозящими переход к технологическому суверенитету. К числу ключевых проблем относятся высокая зависимость от импортного оборудования и сырья, дефицит квалифицированных кадров, а также ограниченная гибкость нормативно-правовой базы, регулирующей обращение с вторичными ресурсами. Решение этих задач требует формирования комплексной государственной стратегии поддержки переработчиков, направленной на стимулирование локализации производственных мощностей, развитие инженерных компетенций и расширение внутреннего рынка полимерного сырья [4].

Цель и задачи исследования

Цель работы – проанализировать текущее состояние и структуру российского рынка переработки пластика, выявить динамику развития отрасли, характерные проблемы, направления технологической модернизации и институциональные барьеры.

Задачи исследования:

1. Провести анализ текущего состояния и структуры рынка переработки пластиковых отходов в РФ.
2. Обобщить виды продукции, получаемые в результате переработки пластиковых отходов.
3. Выполнить классификацию и характеристику основных типов организаций, вовлеченных в процесс переработки пластика в России.
4. Выявить основные вызовы и барьеры, с которыми сталкиваются организации по переработке пластика в Российской Федерации.

Методы исследования

Методологической основой исследования послужили методы системного анализа, сравнительного и сопоставительного анализа, что позволяет выявить общие закономерности и специфические особенности различных подходов к переработке пластика. Также в работе применяются методы анализа отраслевой статистики, нормативно-правовой документации, публичных отчетов предприятий. Проведена классификация пластиков по возможности их переработки (табл. 1). Используется сравнительная характеристика крупнейших переработчиков (табл. 2).

В 2023 году российский рынок полимерных материалов характеризовался опережающим ростом внутреннего потребления, достигшего 7 млн т, по сравнению с объемами отечественного производства. Ключевыми детерминантами выявленной динамики выступили трансформации во внешнеторговой структуре: экспорт полимерного сырья сократился на 28%, в то время как его импорт увеличился на 12%.

Следует отметить, что темпы прироста видимого потребления базовых полимеров (+11,5%) лишь незначительно превысили рост объемов переработки (+9,9%), что указывает на повышение эффективности управления производственно-складскими резервами предприятий отрасли.

Отдельным значимым направлением развития выступило укрепление позиций вторичных полимерных материалов. Совокупная мощность около 900 перерабатывающих предприятий обеспечила выпуск порядка 800 тыс. т вторичного полимерного сырья [4].

Следует учитывать, что технологическим процессам переработки подвергаются не все типы пластмасс. В таблице 1 представлены основные виды пластиков, разделенные по признаку возможности их переработки [5].

Таблица 1

Виды пластиков

Материал	Переработка
Полиэтилентерефталат (ПЭТ)	Полностью перерабатывается
Полиэтилен высокой плотности низкого давления (ПНД)	Полностью перерабатывается
Полихлорвинил (ПВХ)	Не принимается в переработку
Полиэтилен низкой плотности (ПВД)	Полностью перерабатывается
Полипропилен (ПП)	Полностью перерабатывается
Полистирол (ПС)	Технически возможна, но не развита
Полиамид, поликарбонат другие виды пластика	Не перерабатывается

Разные виды пластика перерабатываются по-разному – от этого зависит, какие компании работают на рынке утилизации и как они строят свою работу. Предприятия обычно специализируются на определённых типах пластиков, технологиях и масштабах переработки, что определяет структуру всей отрасли [6]. Такой подход позволяет выделить основные группы компаний и лучше анализировать их работу.

Предприятия, осуществляющие переработку пластиков, подразделяются на два основных типа: организации, специализирующиеся на трансформации использованных изделий в полимерное сырьё и готовую продукцию, а также компании, работающие исключительно с вторичными материалами. В данной статье акцент сделан на предприятиях, осуществляющих переработку пластиковых отходов в новые изделия и вторичное полимерное сырьё. В таблице 2 представлены крупнейшие компании, функционирующие в указанном сегменте отрасли [7–19].

Таблица 2

Переработчики изделий и отходов пластика

Название организации	Что перерабатывают	Объем переработки	Виды продукции	Собственность
ЭкоЛайн-ВторПласт	ПЭТ-бутылки, ПНД-флаконы, ПНД-канистры, ПВД пленки	Более 60 тыс. тонн в год	Гранулы пищевого качества, ПЭТ-флекса, упаковка, паллеты, контейнеры	Частная (Сбер 66%, ППК «РЭО» 28,9%, группа ЭкоЛайн)
TotalCycle (г. Тверь)	Пластиковая упаковка	Около 40 тыс. тонн в год	Гранулы вторичного пластика, пластиковые изделия	Частная (входит в холдинг Технониколь)

Продолжение таблицы 2

Название организации	Что перерабатывают	Объем переработки	Виды продукции	Собственность
РТ-Инвест (Кашира)	Полимерные отходы	До 100 тыс. тонн в год	Гранулы, изделия из ПНД/ПВД, трубы, пленка	Частная (Игорь Ротенберг и др.)
Втор-Пласт (СПБ)	Пластиковые отходы	15 000 тонн гранулы в год	Вторичная гранула, пластиковая тара, упаковка	Частная (Александр Свидовский)
Рециклен (Малоярославец)	Пленочные и пластмассовые отходы	1300 тонн в месяц	ПВД, ЛПВД, ПНД, ПП регрануляты, пленка	Частная (физлица, без госучастия)
ЭкоПласт (в составе ЭкоЛайн)	Вторичная гранула, готовые изделия из пластика	Более 60 тыс. тонн в год	Гранулы, строительные материалы, мебель	Частная (в составе ЭкоЛайн)
Завод ПЭТ-флекса (СПБ)	Пластиковые отходы (ПЭТ)	Около 21 тыс. тонн ПЭТ-флекса в год	ПЭТ-флекса для производства полиэфирного волокна, упаковки	Частная, совместный проект Невский эколого-оператор (госсектор) с «Автопарком №1 Спецтранс»
ЭкоПартнерс (Тверь)	Пластиковая упаковка	40 тыс. тонн в год	Вторичные гранулы, пластиковая тара	Частная
Компания Ростех (РТ-Инвест)	Полимерные отходы	До 100 тыс. тонн в год	Гранулы, трубы, пленка, стройматериалы	Частная (часть группы РТ-Инвест)
Экопластика (регионы РФ)	Пластиковые отходы	Десятки тысяч тонн	Гранулы, пленка, изделия для производства текстиля и упаковки	Частная
ООО «Д-Икс» (Краснодар)	ПЭТ-флекс	Продажа оптом от 17 тонн	ПЭТ-флекс разных цветов для промышленных нужд	Частная
НК Рециклинг (Владивосток)	Пластиковые отходы	50 тонн гранул в месяц	Вторичные гранулы для пищевой упаковки, труб, пакетов	Частная
Базисмаш	ПЭТ-сырье	Более 700 тонн сырья в месяц	ПЭТ-флекс различных цветов, логистика	Частная
Полимеры Сибири	Полиэтиленовые отходы	Значительные объемы (точно не указаны)	Вторичная гранула, пластиковые изделия	Частная
Завод по производству ПЭТ-флекса (Челябинская область)	Пластиковые отходы	Завод на этапе запуска (2025-2026)	ПЭТ-флекс для промышленного использования	Частная

Российский рынок переработки пластика демонстрирует позитивную динамику роста: количество перерабатывающих компаний увеличивается, растут объемы производства специализированных полимеров и продуктов из вторсырья.

Основные технологические и экономические проблемы - зависимость от импортного оборудования и сырья, кадровый дефицит, низкая развитость инфраструктуры раздельного сбора. Это тормозит рост переработки и снижает её экономическую эффективность [20, 21].

Государственные инициативы, включая «мусорную реформу», национальный проект «Экология» и внедрение расширенной ответственности производителя (РОП), создают условия для роста отрасли, стимулируя повышение нормативов утилизации и развитие инфраструктуры. Планируется увеличение переработки пластиковых отходов до 60% к 2030 году с поддержкой химической переработки и технологий термоллиза для сложных отходов [22, 23].

Экономический потенциал рынка переработки в России оценивается в миллиарды долларов с устойчивым ростом. При этом переход на мономатериалы и повышение качества упаковки ускорят развитие переработки и снизят нагрузку на полигоны отходов [22, 24].

Заключение

Современное состояние отрасли переработки пластиков в Российской Федерации демонстрирует одновременно позитивную динамику роста и наличие устойчивых структурных барьеров. Известные решения, направленные на развитие инфраструктуры переработки, такие как «мусорная реформа» и внедрение принципов расширенной ответственности производителя, позволили сформировать институциональную основу для повышения доли вторичных полимеров на рынке. Однако фрагментированность отрасли, высокая зависимость от импортного оборудования и сырья, а также недостаточная обеспеченность квалифицированными кадрами препятствуют достижению системного эффекта. Предлагаемый в исследовании подход, основанный на комплексном сравнительном анализе организаций переработки пластика, позволяет не только выявить текущие ограничения, но и определить направления повышения технологической эффективности и интеграции в экономику замкнутого цикла.

Результаты технико-экономического анализа показывают, что Россия обладает значительным потенциалом для многократного увеличения переработки пластиковых отходов. Ключевым условием является развитие системы сбора и сортировки, поскольку именно эти сегменты остаются наиболее уязвимыми с точки зрения экономики и организации [6]. Капиталовложения в отрасли переработки должны быть существенно увеличены по сравнению с текущим уровнем, причём наибольших вложений требует развитие сортировочных центров и инновационных технологий [6]. Особое значение имеет информационная работа с населением и бизнесом, направленная на формирование устойчивых экологически ответственных моделей поведения, а также на популяризацию раздельного сбора и продукцию из рециклируемых материалов [25].

Проведённый анализ показал, что российский рынок переработки пластмассовых отходов представлен широким спектром предприятий, различающихся по масштабам деятельности, технологическим решениям и видам перерабатываемого сырья. Выявлено, что крупнейшие компании, такие как «ЭкоЛайн-ВторПласт», «РТ-Инвест» и «TotalCycle», демонстрируют высокие объёмы переработки и активно инвестируют в создание современных производственных мощностей. В то же время значительная доля рынка принадлежит малым и микропредприятиям, что обуславливает низкий уровень стандартизации процессов и ограничивает возможности масштабирования. Результаты исследования подтвердили, что ключевые факторы успешного развития отрасли включают диверсификацию технологий переработки, развитие системы раздельного сбора и внедрение химического рециклинга.

Таким образом, основными результатами исследования являются определение структуры российского рынка переработки пластика и обобщение видов продукции, получаемой в результате переработки. Полученные выводы свидетельствуют о необходимости дальнейших усилий в области повышения инвестиционной привлекательности отрасли, стимулирования

внедрения инновационных методов рециклинга и гармонизации нормативно-правовой среды. В перспективе развитие интегрированных кластеров по переработке пластика и активизация государственно-частного партнёрства станут определяющими факторами достижения стратегических целей национального проекта «Экологическое благополучие» и перехода России к экономике замкнутого цикла.

Литература

1. The World's Most Polluting Industries [Электронный ресурс]. Режим доступа: <https://www.worldatlas.com/articles/the-top-10-polluting-industries-in-the-world.html> (Дата обращения 23.10.2025).
2. Арай Ю.Н., Веселова А.С., Кнатько Д.М., Левченко А.В. Создание экономики замкнутого цикла с пластиком и без него: стратегический вызов для компании "СИБУР" // Вестник Санкт-Петербургского университета. Менеджмент. 2022. № 4. С. 575–600.
3. Шилкина С.В. Управление пластиковыми отходами: российский и зарубежный опыт Отходы и ресурсы. 2022. Т. 9. № 1. DOI:10.15862/10ECOR122.
4. Кацевман М.Л. Состояние российской отрасли переработки пластмасс [Электронный ресурс]. Режим доступа: <https://polymerbranch.com/articles/sostoyanie-rossijskoj-otrasli-pererabotki-plastmass/> (Дата обращения 23.10.2025).
5. Ратнер С.В. Управление инновациями в сфере обращения с пластиком: опыт международной инициативы «Новая экономика пластика» // Научно-практический ежемесячный журнал. 2020. №. 5(259). С. 32–40.
6. Капустин Н.О. Перспективы развития отрасли переработки пластиковых отходов в России // Проблемы прогнозирования. 2025. № 3 (210). С. 82–95. DOI: 10.47711/0868-6351-210-82-95.
7. ЮНЕП: Годовой отчет за 2024 год [Электронный ресурс]. Режим доступа: <https://www.unep.org/annualreport/ru/2024> (Дата обращения 23.10.2025).
8. Pollution killing 9 million people a year, Africa hardest hit - study [Электронный ресурс]. Режим доступа: <https://www.reuters.com/business/environment/pollution-killing-9-million-people-year-africa-hardest-hit-study-2022-05-17/> (Дата обращения 23.10.2025).
9. Состояние российской отрасли переработки пластмасс [Электронный ресурс]. Режим доступа: <https://polymerbranch.com/articles/sostoyanie-rossijskoj-otrasli-pererabotki-plastmass/> (Дата обращения 23.10.2025).
10. В России запущен крупнейший завод по переработке пластика [Электронный ресурс]. Режим доступа: https://www.rbc.ru/spb_sz/19/04/2024/662268179a7947d63e4922c4 (Дата обращения 23.10.2025).
11. Вторичная переработка пластмасс: перспективы и риски отрасли [Электронный ресурс]. Режим доступа: <https://polymerbranch.com/articles/vtorichnaya-pererabotka-plastmass-perspektivy-i-riski-otrasli/> (Дата обращения 23.10.2025).
12. Рециклен [Электронный ресурс]. Режим доступа: <https://recyclene.ru> (Дата обращения 23.10.2025).
13. Крупнейший в регионе завод по переработке пластика за 17 млрд рублей появится на Волхонском шоссе [Электронный ресурс]. Режим доступа: <https://newprospect.ru/news/pmef-2025-krupnejshij-v-regione-zavod-po-pererabotke-plastikov-za-17-mlrd-rublej-poyavitsya-na-volxonskom-shosse> (Дата обращения 23.10.2025).
14. Справочник «Полимерная индустрия 2025» [Электронный ресурс]. Режим доступа: https://plastinfo.ru/information/news/54739_03.02.2025 (Дата обращения 23.10.2025).
15. ПЭТ-флекс [Электронный ресурс]. Режим доступа: <https://productcenter.ru/products/121756/pet-fleks> (Дата обращения 23.10.2025).
16. Единственный на Дальнем Востоке завод по переработке старого пластика в гранулы для производства упаковки запустил резидент СПВ во Владивостоке [Электронный ресурс]. Режим доступа: https://chaogov.ru/press-tsentr/novosti_dv/edinstvennyy-na-dalnem-vostoke-zavod-po-pererabotke-starogo-plastika-v-granuly-dlya-proizvodstva-upa/ (Дата обращения 23.10.2025).
17. Полимеры Сибири [Электронный ресурс]. Режим доступа: <https://xn--90ahibbarjprjqdj3l.xn--p1ai/o-nas/> (Дата обращения 23.10.2025).
18. Крупнейший завод России по переработке пластиковых отходов вошел в реестр утилизаторов Минприроды [Электронный ресурс]. Режим доступа: <https://news.solidwaste.ru/2025/02/krupnejshij-zavod-rossii-po-pererabotke-plastikovyh-othodov-voshel-v-reestr-utilizatorov-minprirody/> (Дата обращения 23.10.2025).

19. Завод по производству ПЭТ-флекса заработает в Челябинской области в 2026 году [Электронный ресурс]. Режим доступа: <https://www.lobl.ru/news/ekonomika/zavod-po-proizvodstvu-pet-fleksa-zarabotaet-v-chelyabinskoy-oblasti-v-2026-godu/> (Дата обращения 23.10.2025).
20. Итоги II Сырьевой конференции СПП: Переработка пластмасс - вызовы, решения, перспективы [Электронный ресурс]. Режим доступа: <https://ruplastica.ru/news/20250521-itogi-ii-syrevooy-konferencii-spp-pererabotka-plastmass-vyzovy-resheniya-perspektivy> (Дата обращения 23.10.2025).
21. В Петербурге построят завод по переработке пластика за 1,7 млрд рублей [Электронный ресурс]. Режим доступа: <https://rupec.ru/news/53467/> (Дата обращения 23.10.2025).
22. Полимерная упаковка: текущая ситуация и перспективы развития [Электронный ресурс]. Режим доступа: <https://rosupack.com/ru/media/news/2025/october/16/polimernaya-upakovka> (Дата обращения 23.10.2025).
23. В Петербурге построят завод по переработке пластика за 1,7 млрд рублей [Электронный ресурс]. Режим доступа: <https://rupec.ru/news/53467/> (Дата обращения 23.10.2025).
24. Рынок пластмасс в России: вызовы, перспективы и стратегия развития в 2025 году [Электронный ресурс]. Режим доступа: <https://delprof.ru/press-center/experts-pubs/rynok-plastmass-v-rossii-vyzovu-perspektivy-i-strategiya-razvitiya-v-2025-godu/> (Дата обращения 23.10.2025).
25. Правительство утвердило правила обращения с твердыми коммунальными отходами [Электронный ресурс]. Режим доступа: <https://www.garant.ru/article/1471040/> (Дата обращения 23.10.2025).

Оглавление

Прикладная аналитика.....	4
Большаков Г.В., Рогаткин Н.А. ЭНЕРГОПОТРЕБЛЕНИЕ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ: СИСТЕМНЫЙ ПОДХОД К ОПТИМИЗАЦИИ И УСТОЙЧИВОМУ РАЗВИТИЮ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА.....	4
Большаков Г.В., Новиков В.В., Рогаткин Н.А. ВЛИЯНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА НА ТРАНСФОРМАЦИЮ ИНДУСТРИИ РАЗВЛЕЧЕНИЙ.....	8
Кушнер Д.В., Тимофеева С.М. ПЕРСПЕКТИВЫ ВНЕДРЕНИЯ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ АНАЛИЗА КУРСА ВАЛЮТ.....	12
Сорокин А.А. АНАЛИЗ И ПРОГНОЗИРОВАНИЕ ЭНЕРГОПОТРЕБЛЕНИЯ ПРОМЫШЛЕННЫХ ПРЕДПРИЯТИЙ С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ	17
Фитковская Я.А. ОБРАБОТКА ДОРЕФОРМЕННЫХ РУССКИХ ТЕКСТОВ: АНАЛИЗ ЭФФЕКТИВНОСТИ LLM ДЛЯ КОРРЕКЦИИ OCR-ОШИБОК НА ПРИМЕРЕ YANDEX VISION OCR И YANDEXGPT	23
Экономика, финансы и устойчивое развитие	28
Половинкин В.В., Соложенкина Е.Е. АНАЛИЗ УРОВНЯ БЕЗРАБОТИЦЫ В РОССИИ В ПОСТПАНДЕМИЙНЫЙ ПЕРИОД.....	28
Половинкин В.В., Соложенкина Е.Е. ПРИМЕНЕНИЕ И ОЦЕНКА КОНЦЕПЦИИ СРЕДНЕВЗВЕШЕННОЙ СТОИМОСТИ КАПИТАЛА (WACC) ДЛЯ ФИНАНСИРОВАНИЯ ДЕЯТЕЛЬНОСТИ ПРОМЫШЛЕННОГО ПРЕДПРИЯТИЯ НА ПРИМЕРЕ ПАО «СЕВЕРСТАЛЬ»	32
Стрельцова Я.А., Усов Е.С. СРАВНИТЕЛЬНЫЙ АНАЛИЗ ОРГАНИЗАЦИЙ В РФ ПО ПЕРЕРАБОТКЕ ПЛАСТИКА	36

Известия студенческой науки

Сборник научных трудов

Выпуск 1. Том 1

Текстовое электронное издание

Минимальные системные требования:

Компьютер: процессор x86 с тактовой частотой 500 МГц и выше; ОЗУ 512 Мб; 8Мб на жёстком

диске; видеокарта SVGA 1280x1024 High Color (32 bit); привод CD-ROM.

Операционная система: Windows XP/7/8 и выше.

Программное обеспечение: Adobe Acrobat Reader версии 6 и старше.

Редакционно-издательский отдел Университета ИТМО

Зав. РИО

Дизайн обложки

Вёрстка

Подписано к печати 14.11.2025

Объем издания 2235 Мб

Заказ № 4799 от 14.11.2025

Материалы печатаются в авторской редакции

Н.Ф. Гусарова

П.А. Леушина

К.Д. Бутылкина

ISBN 978-5-7577-0739-6



9 785757 707396 >

ИТМО