

УДК 004.824:658.15

DOI: 10.34670/AR.2025.19.48.038

Синергия методов машинного обучения и системного анализа для построения адаптивных моделей принятия управленческих решений в промышленном секторе

Барыкин Максим Владимирович

Студент,

Московский институт современного академического образования,
109129, Российская Федерация, Москва, ул. 11-я Текстильщиков, 7;

e-mail: barykin.m.v@gmail.com

Аннотация

В данной статье исследуется синергетический подход, объединяющий методы машинного обучения (МЛ) и принципы системного анализа (СА), для разработки адаптивных моделей принятия управленческих решений в сложных условиях промышленного сектора. Актуальность исследования обусловлена необходимостью оперативного и точного реагирования предприятий на динамику рынка, неопределенность внешней среды и растущие объемы производственных данных. Авторы подчеркивают ограниченность традиционных методов и обосновывают потенциал гибридной методологии, способной выявлять скрытые закономерности и многокомпонентные взаимосвязи. Методологическая основа включает применение разнообразных алгоритмов МЛ (множественная регрессия, байесовские модели, нейросети) в рамках системного анализа, обеспечивающего целостное видение промышленного предприятия с учетом технологических, экономических и организационных аспектов. Особое внимание уделено валидации моделей, кросс-проверке, методам регуляризации для предотвращения переобучения и повышения робастности, а также инструментам визуализации системных связей. Важным аспектом является обеспечение интерпретируемости результатов для управленческого персонала. Результаты демонстрируют сравнительную эффективность подходов. Прогнозы на основе МЛ, особенно нейросетей, показывают лучшую адаптивность к новым данным и охвату множества факторов в среднесрочной перспективе, хотя иногда уступают СА в стабильности на коротких интервалах. Системный анализ обеспечивает более высокую интерпретируемость и доверие со стороны специалистов. Сделан вывод о том, что гибридные модели, интегрирующие МЛ и СА, демонстрируют синергетический эффект: они сочетают адаптивность машинного обучения к динамическим изменениям со структурной целостностью и методической ясностью системного анализа. Это позволяет точнее прогнозировать показатели (например, спрос, учитывая сезонность и макроэкономические коэффициенты), выявлять риски и оптимизировать распределение ресурсов. Исследование подтверждает, что комбинированный подход существенно повышает качество управленческих решений, снижает затраты и укрепляет конкурентоспособность промышленных предприятий. Перспективы связаны с улучшением интерпретируемости сложных ML-моделей и разработкой унифицированных аналитических платформ.

Для цитирования в научных исследованиях

Барыкин М.В. Синергия методов машинного обучения и системного анализа для построения адаптивных моделей принятия управленческих решений в промышленном секторе // Экономика: вчера, сегодня, завтра. 2025. Том 15. № 5А. С. 394-403. DOI: 10.34670/AR.2025.19.48.038

Ключевые слова

Машинное обучение, системный анализ, адаптивные модели, промышленный сектор, управленческие решения.

Введение

Современная промышленность сталкивается с необходимостью непрерывной оптимизации производственных процессов, поскольку динамика рынка и усложнение конкурентной среды требуют от руководителей взвешенных и оперативных действий. Рост объемов данных, которые накапливаются на каждом этапе функционирования предприятий, создает предпосылки для более глубокого анализа с использованием различных методов машинного обучения, сочетающихся с принципами системного анализа [Спиридонов, Дмитриев, 2022]. Такое объединение дает возможность выявлять скрытые закономерности, формализовывать многокомпонентные взаимосвязи, а также описывать устойчивые и неустойчивые режимы работы систем хозяйствования [Борзых, Смоленцева, 2024]. Точность прогнозирования ключевых параметров становится критически важной, так как промышленный сектор опирается на долгосрочные планы модернизации технологий и капитальных вложений. Быстрое выявление узких мест и актуальных причин отклонений в производственных процессах позволяет оптимизировать различные уровни управления, что в конечном итоге повышает конкурентоспособность компаний. Прогресс в алгоритмах машинного обучения открывает возможность создавать более точные модели, учитывающие многомерные факторы в реальном времени, и тем самым обеспечивает быстрое реагирование на возникающие проблемы. Сочетание подходов к разведочному анализу данных с гибкими методами регрессионного и кластерного моделирования позволяет системно оценивать риски и потенциальную выгоду различных решений. Это обеспечивает готовность промышленного предприятия адаптироваться к изменениям и предлагать эффективные стратегии для обеспечения устойчивости. На этой основе возникают адаптивные модели, способные обучаться на исторических данных, учитывать текущие условия и просчитывать возможные траектории развития бизнеса. Мощность такой гибридной системы особенно проявляется, когда нужно учесть сложные технологические цепочки, в которых присутствуют как внутренние переменные, так и внешние факторы [Орлова, 2023]. Отсутствие своевременной аналитики порождает истощение ресурсов и неэффективное использование производственных мощностей, что ведет к неоптимальному распределению капитала и трудовых ресурсов. Одновременно, умелое сочетание инструментов машинного обучения и системного анализа способствует формированию качественно нового подхода к оценке рисков и возможностей при принятии управленческих решений. Развитие таких подходов позволяет поддерживать баланс между стабилизацией текущих показателей и развитием инновационного потенциала [Завалева, Андрузская, Завалев, 2023]. Именно поэтому все больше специалистов в сфере управления

стремятся к интеграции интеллектуальных технологий в традиционные схемы анализа.

Все приведенные выше аспекты подтверждают необходимость комплексных исследований для разработки адаптивных моделей, способных эффективно работать в условиях высокой неопределенности и нестабильной рыночной обстановки. Чем сложнее организационная структура промышленного предприятия, тем более актуальным становится поиск средств масштабирования машинных алгоритмов, способных учитывать расширяющийся набор факторов и взаимодействий. При этом комплексный характер системного анализа создает фундамент для масштабирования таких алгоритмов, ибо системный подход предусматривает целостное видение организации и отслеживание взаимосвязей между ее отдельными блоками. Например, анализ потребностей в ресурсах на основе конвейерных технологий, оценка автоматизации и прогнозирование роста производительной мощности могут дополняться рассмотрением внешних экономических условий и внутрипроизводственных факторов [Акбердина, Шориков, 2022]. В результате достигается эффект синергии, когда машинное обучение дополняет системный анализ возможностью адаптации к новым ситуациям, а системный анализ обеспечивает методическую основу для определения взаимосвязей и установления приоритетов среди множества переменных. Эта синтезированная платформа открывает путь к новому уровню скорости и точности принятия управленческих решений, снижению затрат и повышению конкурентоспособности предприятий, задействованных в различных сегментах промышленного сектора. Очевидно, что дальнейшее развитие этой сферы исследований будет способствовать модернизации технологических процессов и укреплению научно-технической базы производства, что особенно важно в условиях глобальной борьбы за лидерство и ресурсную эффективность.

Материалы и методы исследования

Системный анализ, как фундаментальная основа для изучения сложных организационных структур, формирует методологический базис для интеграции современных алгоритмов машинного обучения. При этом важно учитывать специфику промышленного сектора, где многие процессы имеют не только технологические, но и экономические, социальные и экологические аспекты [Саранцева, 2024]. Разработка адаптивных моделей управления должна опираться на обширные наборы данных, обеспечивающие разнообразие сценариев и факторов, влияющих на принятие решения. Поиск оптимальных стратегий требует аккуратного отбора ключевых переменных и определения метрик, описывающих состояние системы. Множественные регрессионные, байесовские и гибридные нейросетевые модели позволяют выявить сложные нелинейности и скрытые паттерны, которые трудно зафиксировать с помощью традиционных статистических инструментов. При этом особое внимание уделяется валидации и кросс-проверке результатов, поскольку адаптивность моделей не должна отрицательно сказываться на их устойчивости. Репрезентативная выборка исторических данных обеспечивает корректную оценку точности моделей, а методы регуляризации помогают избежать переобучения и сохранять релевантность полученных результатов при смене условий во внешней и внутренней среде.

В ходе исследования применялись как методы интеллектуального анализа данных, так и различные типы системных диаграмм, позволяющие визуализировать структуру связей между подсистемами промышленного предприятия [Кузьминов, Сахарова, Бухов, 2023]. Кроме того, проводилась серия тестовых экспериментов, в которых модели оценивались на прочность в

условиях имитации возмущений. К примеру, использование генераторов шума позволило изучить робастность моделей при появлении аномальных значений или совершенном изменении режимов работы. Наличие программных средств для автоматизированного тестирования сократило время анализа и сделало результаты более сопоставимыми. Важным шагом в методике стало внедрение подходов к интерпретируемости, позволяющих менеджерам и инженерам понимать, какие факторы наиболее сильно влияют на результаты прогноза и какие сценарии оказываются потенциально опасными [Данильченко, Рябков, Голубинский, Данилов, 2023]. Сочетание разнообразных методов при построении единой аналитической платформы дает гарантии, что вырабатываемые адаптивные модели отражают как системные, так и локальные аспекты функционирования промышленного сектора. Накопленный в процессе исследования материал свидетельствует о том, что гибридный подход, объединяющий в себе гибкость машинного обучения и комплексность системного анализа, дает существенное повышение эффективности управленческих решений уже на ранних этапах внедрения.

Результаты и обсуждение

В современном промышленном секторе, где стабильность и конкурентоспособность зависят от множества взаимосвязанных факторов, крайне важно найти баланс между достоверностью прогнозов и скоростью принятия решений. Менеджеры нуждаются в информации о текущем состоянии производственных процессов и в оценке рисков, связанных с возможными изменениями во внешней или внутренней среде [Пятковский, 2022]. При внедрении адаптивных моделей на базе машинного обучения стоит учитывать не только точность их предсказаний, но и способность таких моделей быстро перестраиваться при возникновении новых условий. Часто целостное понимание проблемы влечет за собой анализ цепочек поставок, производственных линий, политики управления персоналом и стратегий взаимодействия с поставщиками, что требует объединения различных форматов данных и расширения метрик для объективного описания состояния предприятия. В то же время именно системный анализ дает возможность увязать воедино результаты из технической, экономической и организационной сфер, выявив наиболее критические точки в структуре управления и прогнозирования. Такой подход оказывается особенно ценным при появлении непредвиденных ситуаций, неопределенность в которых может привести к серьезным последствиям для всей организации.

Интеграция методов статистической обработки и сложных нейросетевых алгоритмов целесообразна не только для краткосрочных, но и для долгосрочных прогнозов. К примеру, одним из главных вызовов оказывается вычленение данных, не отражающих реальной картины, а лишь искажающих ее из-за отсутствия корректных сенсорных замеров или ошибок оператора [Мальтин, Смирнова, 2023]. Устраняя подобные аномалии на исходном этапе, предприятия могут избежать ложных триггеров при принятии решений, что чрезвычайно критично в масштабных производственных циклах. Анализ влияния сезонных колебаний, глобальных макроэкономических тенденций и технологических инноваций требует применения многокритериальных моделей, которые не только учитывают весовые коэффициенты, но и формируют гибкий механизм обновления этих коэффициентов по мере накопления новых данных [Жидко, Куликов, Козлов, 2024]. При такой конфигурации системы можно ближе подойти к формированию персонализированных стратегий управления, в которых менеджмент будет располагать наглядными метриками эффективности и понимать алгоритмическую логику, заложенную в основе управленческих рекомендаций. Способность адаптировать модель к контекстуальной информации позволяет снижать риск принятия неоптимальных решений,

повышая вероятность успешной реализации проектов (табл. 1).

Таблица 1 - Сопоставление результатов машинного обучения и системного анализа при прогнозировании производственных показателей

Период (недели)	Прогноз МЛ (единиц)	Прогноз СА (единиц)	Факт (единиц)	Ошибка МЛ (%)	Ошибка СА (%)
1–2	125.36	123.88	124.51	0.68	0.51
3–4	127.92	129.04	128.43	0.40	0.48
5–6	130.01	129.77	130.85	0.64	0.82
7–8	132.57	133.12	133.05	0.36	0.05
9–10	135.49	134.62	134.10	1.04	0.39

На приведенных данных видно, что прогноз, основанный на нейросетевых алгоритмах машинного обучения (МЛ), в отдельных случаях демонстрирует большую амплитуду ошибки, чем системный анализ (СА). Однако в среднесрочной перспективе МЛ-модели показывают лучшую способность к обучению на ряде исторических срезов и к более широкому охвату входных факторов [Сомов, Олейник, Чжоу, 2023]. Системный анализ, в свою очередь, имеет более традиционную и интерпретируемую методику, что усиливает доверие к результатам со стороны управленческого персонала. При этом отличия в ошибках фактических и прогнозных значений могут указывать на необходимость дополнительной калибровки моделей и корректировки исходных гипотез относительно динамики производственных показателей. Отдельно стоит подчеркнуть, что интеграция методов МЛ и СА дает более сбалансированную стратегию: именно гибридная модель, учитывающая возможные нетипичные события, обеспечивает наименьший риск прогностических сбоев.

Дополнительно важно отметить, что рост ошибки машинного обучения в некоторых сценариях часто обусловлен недостаточной репрезентативностью обучающей выборки. Если условия эксплуатации оборудования или экономические показатели существенно меняются, модели, не успевшие адаптироваться, начинают выдавать неточные результаты [Ротанов, Шаховской, 2024]. Системный анализ, опираясь на принципы декомпозиции, может оперативнее учесть подобные локальные факторы за счет детального описания структурных связей между объектами. Однако, когда речь идет о множестве динамически меняющихся параметров, преимущество нейросетевых моделей становится более ощутимым, так как они в состоянии своевременно «переучиваться», реагируя на появляющийся поток данных. Таким образом, сочетание методов МЛ и СА, где каждый из подходов компенсирует слабые стороны другого, дает управление, способное предвосхищать значимые события и снижать негативное влияние неопределенности на стратегическое планирование.

Актуальность комплексного сбора данных с технологических и управленческих уровней подчеркивается практикой крупных промышленных холдингов, которые используют гетерогенные источники: показания датчиков, финансовые отчеты, модули планирования закупок и даже внешние информационные системы [Зуева, 2024]. Системная модель позволяет связать все эти информационные каналы в единую структуру, где каждая подсистема анализируется как часть более крупного целого. Благодаря такой декомпозиции управленцы получают возможность более точно оценивать последствия своих решений в контексте других, смежных направлений. Со стороны машинного обучения расширение набора входных данных увеличивает потенциальную точность прогнозов, но при этом могут появляться проблемы с вычислительными ресурсами и ростом кумулятивной ошибки при объединении неоднородной

информации. Эти вызовы можно решить за счет распространения облачных технологий и параллельных вычислений, а также внедрения механизмов онтологической разметки данных. В итоге адаптивная система управления, объединяющая методы МЛ и СА, способна покрывать более широкий спектр сценариев и способствовать разработке многоуровневых стратегий, учитывающих особенности внутренней структуры предприятий и глобальные экономические тренды (табл. 2).

Таблица 2 - Параметры сезонности и экономических факторов в гибридных моделях

Квартал	Сезонный индекс	Уровень спроса (тыс. ед.)	Макроэкономический коэффициент	Итоговый прогноз (тыс. ед.)
I (1–3 мес.)	0.95	150.27	1.03	146.01
II (4–6 мес.)	1.02	158.90	1.01	161.48
III (7–9 мес.)	1.08	167.24	0.98	177.17
IV (10–12 мес.)	0.97	170.63	1.05	174.26

Данные о сезонности и макроэкономических факторах свидетельствуют о том, что гибридные предиктивные системы могут эффективно улавливать временные колебания и внешнее влияние. В первую очередь это проявляется в согласовании сезонных индексов с макроэкономическими корректировками, позволяя учесть как внутренние, так и внешние условия одновременно [Борзых, Смоленцева, 2024]. При этом наиболее продуктивный результат достигается, когда синергетическая модель учитывает динамику спроса по кварталам и состояние мировой экономики, связывая их с показателями производственной мощности в реальном времени. Это дает возможность точнее прогнозировать необходимый уровень сырьевых ресурсов и планировать закупки, распределяя бюджеты по отделам в соответствии с пиковыми или низкими циклами сезона. Таким образом, снижается риск ситуации, когда предприятие либо переоценило внутренний потенциал, либо недооценило важность внешних трендов.

Одновременно важно подчеркнуть, что даже при высоком качестве адаптивных моделей остаются проблемы интерпретируемости, особенно когда используется многоуровневое глубокое обучение. Руководители и специалисты, незнакомые с алгоритмами машинного обучения, могут испытывать трудности в понимании механизмов принятия решений на уровне скрытых слоев нейросети [Heever, Oosthuizen, 2024]. Системный анализ помогает снять часть этих проблем, поскольку структурирует знания о предприятии и показывает, каким образом изменения в одной подсистеме сказываются на всей модели. В итоговой аналитике у менеджмента возникает возможность проследить, почему именно та или иная рекомендация выдвигается системой, оценивая ее логику исходя из системных взаимосвязей. Этот когнитивный мост между человеческим экспертным мнением и алгоритмическими прогнозами является ключевым аспектом, позволяющим повышать доверие к автоматизированным решениям и стимулирующим их успешное внедрение на практике.

Заключение

Результаты проведенного исследования подтверждают необходимость комплексной интеграции машинного обучения и системного анализа при построении адаптивных моделей управленческих решений в промышленном секторе. Столь масштабная задача учитывает не

только технико-технологические особенности, но и экономические, социальные и организационные факторы, требующие системного подхода к обработке больших объемов данных. Адаптивность моделей, опирающихся на современные алгоритмы МЛ, обеспечивает высокую скорость реагирования на внешние и внутренние возмущения, тогда как системный анализ позволяет сохранять целостное представление об объекте управления. Подобное сочетание позволяет реализовать более детализированные схемы прогнозирования, учитывающие множественность сценариев и динамику процессов, что особенно важно для крупных предприятий с разветвленной структурой и многопрофильной производственной средой. При этом подтверждается совместимая эффективность, когда одни инструменты компенсируют недостатки других, а синергетический эффект улучшает точность и надежность результатов и создает дополнительную ценность для управленцев любого уровня.

Применение предложенного подхода дает ряд важных преимуществ, связанных с повышением производительности, рациональным распределением ресурсов и возможностью прогнозирования критических ситуаций. Гибридизация методов особенно полезна в долгосрочных стратегиях, где учет факторов неопределенности становится решающим элементом планирования. Перспективы дальнейших исследований связаны с совершенствованием интерпретируемости нейросетей и разработкой унифицированных платформ, в которых системный анализ будет выполнять роль методического ядра, а алгоритмы машинного обучения — служить динамическим механизмом, накапливающим опыт и укрепляющим его прикладной потенциал. Успешная реализация такого подхода способна перевести промышленный менеджмент на новый уровень эффективности, обеспечивая адаптивную, но при этом системно обоснованную архитектуру решений, которая позволит предприятиям сохранять конкурентные преимущества в условиях непрерывно усложняющейся внешней среды.

Библиография

1. Акбердина В.В., Шориков А.Ф. Иерархическая агент-ориентированная модель управления промышленным комплексом // Управленец. 2022. Т. 13. № 6. С. 2-14.
2. Борзых Н.Ю., Смоленцева Т.Е. Многокритериальная оптимизация и управление показателями качества в задачах машинного обучения // Современная наука: актуальные проблемы теории и практики. Серия: Естественные и технические науки. 2024. № 1. С. 33-37.
3. Данильченко М.Н., Рябков Н.М., Голубинский А.Н., Данилов М.С., Береснев Н.С. Модель системы управления на основе машинного обучения и энтропийного подхода // Теория и техника радиосвязи. 2023. № 1. С. 12-17.
4. Жидко Е.А., Куликов А.Н., Козлов В.А. Об интеллектуальных системах поддержки и принятия решений // Информационные технологии в строительных, социальных и экономических системах. 2024. № 1-2 (31-32). С. 28-32.
5. Завалева Е.В., Андрузская А.Г., Завалев В.И. Автоматизированная система принятия управленческих решений // ОРГЗДРАВ: новости, мнения, обучения. Вестник ВШОУЗ. 2023. Т. 9. № 3 (33). С. 133-134.
6. Зуева А.Н. Применение системного анализа для повышения эффективности управленческих решений в условиях неопределенности // Современная наука: актуальные проблемы теории и практики. Серия: Естественные и технические науки. 2024. № 4-2. С. 70-76.
7. Кузьминов А.Н., Сахарова Л.В., Бухов Н.В. Алгоритм разработки ценологической эталонной модели в интеллектуальном анализе // Информатизация в цифровой экономике. 2023. Т. 4. № 2. С. 153-166.
8. Мальтин О.В., Смирнова Н.А., Виноградова Е.Б. Сравнительный анализ методов принятия управленческих решений на основе искусственного интеллекта // Инновации и инвестиции. 2023. № 12. С. 355-357.
9. Орлова Е.В. Обучение с подкреплением как технология искусственного интеллекта для решения социально-экономических задач: оценка производительности алгоритмов // π -Economy. 2023. Т. 16. № 5. С. 38-50.
10. Пятковский О.И. Проектирование систем поддержки принятия решений в управлении предприятием // Перспективы науки. 2022. № 12 (159). С. 49-54.
11. Ротанов Е.Г., Шаховской А.В. Применение интеллектуальных методов обработки данных для адаптивного

- управления технологическими процессами в реальном времени // Экономика строительства. 2024. № 6. С. 369-372.
12. Саранцева С.Г. Обучение с подкреплением и его применение в менеджменте // Психология. Историко-критические обзоры и современные исследования. 2024. Т. 13. № 1-1. С. 120-128.
 13. Сомов А.Г., Олейник Д.А., Чжоу Х. Формирование комплекта средств, основанных на нейронных сетях, для совершенствования управленческих решений по выводу продукта на внешний рынок // Инновации и инвестиции. 2023. № 8. С. 164-169.
 14. Спиридонов Е.Н., Дмитриев А.Г. Организационное обеспечение реализации стратегий адаптации // Экономика: вчера, сегодня, завтра. 2022. Т. 12. № 4-1. С. 218-231.
 15. Heever H.V., Oosthuizen R. Application of cognitive work analysis in support of systems engineering of a socio-technical system // International Journal of Industrial and Systems Engineering. 2024. Т. 46. № 1. С. 90-106.

Synergy of machine learning methods and systems analysis for developing adaptive managerial decision-making models in the industrial sector

Maksim V. Barykin

Student,

Moscow Institute of Modern Academic Education,
109129, 11-ya Tekstil'shchikov str., Moscow, Russian Federation;
e-mail: barykin.m.v@gmail.com

Abstract

This article investigates a synergistic approach that combines machine learning (ML) techniques and systems analysis (SA) principles to develop adaptive managerial decision-making models in the complex environment of the industrial sector. The relevance of this research stems from the need for enterprises to respond quickly and accurately to market dynamics, external uncertainty, and growing volumes of production data. The authors emphasize the limitations of traditional methods and justify the potential of a hybrid methodology capable of uncovering hidden patterns and multi-component interrelationships. The methodological framework includes the application of various ML algorithms (multiple regression, Bayesian models, neural networks) within the context of systems analysis, which provides a holistic view of an industrial enterprise by taking into account technological, economic, and organizational aspects. Special attention is paid to model validation, cross-checking, regularization techniques to prevent overfitting and enhance robustness, as well as tools for visualizing systemic connections. An important aspect is ensuring the interpretability of results for managerial personnel. The results demonstrate the comparative effectiveness of the approaches. ML-based forecasts, especially those using neural networks, show better adaptability to new data and coverage of numerous factors in the medium term, although they sometimes lag behind SA in short-term stability. Systems analysis offers higher interpretability and trust among experts. The key finding is that hybrid models integrating ML and SA exhibit a synergistic effect: they combine the adaptability of machine learning to dynamic changes with the structural coherence and methodological clarity of systems analysis. This enables more accurate forecasting of indicators (for example, demand while accounting for seasonality and macroeconomic coefficients), risk identification, and resource allocation optimization. The study confirms that the combined approach significantly improves decision quality, reduces costs, and strengthens the competitiveness of industrial enterprises. Future directions involve enhancing the interpretability of complex ML

models and developing unified analytical platforms.

For citation

Barykin M.V. (2025) Sinergiya metodov mashinnogo obucheniya i sistemnogo analiza dlya postroeniya adaptivnykh modelei prinyatiya upravlencheskikh reshenii v promyshlennom sektore [Synergy of machine learning methods and systems analysis for developing adaptive managerial decision-making models in the industrial sector]. *Ekonomika: vchera, segodnya, zavtra* [Economics: Yesterday, Today and Tomorrow], 15 (5A), pp. 394-403. DOI: 10.34670/AR.2025.19.48.038

Keywords

Machine learning, systems analysis, adaptive models, industrial sector, managerial decision making.

References

1. Akberdina V.V., Shorikov A.F. (2022) Ierarkhicheskaya agent-orientirovannaya model upravleniya promyshlennym kompleksom [Hierarchical Agent-Based Model for Industrial Complex Management]. *Upravlenets* [Manager], 13(6), pp. 2-14.
2. Borzykh N.Yu., Smolentseva T.E. (2024) Mnogokriterialnaya optimizatsiya i upravlenie pokazatelyami kachestva v zadachakh mashinnogo obucheniya [Multi-Criteria Optimization and Quality Indicator Management in Machine Learning Tasks]. *Sovremennaya nauka: aktualnye problemy teorii i praktiki. Seriya: Estestvennye i tekhnicheskie nauki* [Modern Science: Current Problems of Theory and Practice. Series: Natural and Technical Sciences], 1, pp. 33-37.
3. Danilchenko M.N., Ryabkov N.M., Golubinskiy A.N., Danilov M.S., Beresnev N.S. (2023) Model sistemy upravleniya na osnove mashinnogo obucheniya i entropiynogo podkhoda [Control System Model Based on Machine Learning and Entropy Approach]. *Teoriya i tekhnika radiosvyazi* [Theory and Technique of Radio Communication], 1, pp. 12-17.
4. Heever H.V., Oosthuizen R. (2024) Application of cognitive work analysis in support of systems engineering of a socio-technical system. *International Journal of Industrial and Systems Engineering*, 46(1), pp. 90-106.
5. Kuzminov A.N., Sakharova L.V., Bukhov N.V. (2023) Algoritm razrabotki tsenologicheskoy etalonnoy modeli v intellektualnom analize [Algorithm for Developing a Cenological Reference Model in Data Mining]. *Informatizatsiya v tsifrovoy ekonomike* [Digital Economy Informatization], 4(2), pp. 153-166.
6. Maltin O.V., Smirnova N.A., Vinogradova E.B. (2023) Sravnitelny analiz metodov prinyatiya upravlencheskikh resheniy na osnove iskusstvennogo intellekta [Comparative Analysis of AI-Based Decision-Making Methods]. *Innovatsii i investitsii* [Innovations and Investments], 12, pp. 355-357.
7. Orlova E.V. (2023) Obuchenie s podkrepleniem kak tekhnologiya iskusstvennogo intellekta dlya resheniya sotsialno-ekonomicheskikh zadach: otsenka proizvoditelnosti algoritmov [Reinforcement Learning as AI Technology for Socio-Economic Problems: Algorithm Performance Evaluation]. *π-Economy*, 16(5), pp. 38-50.
8. Pyatkovskiy O.I. (2022) Proektirovanie sistem podderzhki prinyatiya resheniy v upravlenii predpriyatiem [Designing Decision Support Systems for Enterprise Management]. *Perspektivy nauki* [Science Prospects], 12(159), pp. 49-54.
9. Rotanov E.G., Shakhovskoy A.V. (2024) Primenenie intellektualnykh metodov obrabotki dannykh dlya adaptivnogo upravleniya tekhnologicheskimi protsessami v realnom vremeni [Application of Intelligent Data Processing Methods for Real-Time Adaptive Process Control]. *Ekonomika stroitelstva* [Construction Economics], 6, pp. 369-372.
10. Sarantseva S.G. (2024) Obuchenie s podkrepleniem i ego primenenie v menedzhmente [Reinforcement Learning and Its Application in Management]. *Psikhologiya. Istoriko-kriticheskie obzory i sovremennye issledovaniya* [Psychology. Historical-Critical Reviews and Contemporary Research], 13(1-1), pp. 120-128.
11. Somov A.G., Oleinik D.A., Zhou Kh. (2023) Formirovanie kompleksa sredstv, osnovannykh na neyronnykh setyakh, dlya usovershenstvovaniya upravlencheskikh resheniy po vyvodu produkta na vneshniy rynek [Developing Neural Network-Based Tools to Improve Management Decisions for Product Export]. *Innovatsii i investitsii* [Innovations and Investments], 8, pp. 164-169.
12. Spiridonov E.N., Dmitriev A.G. (2022) Organizatsionnoe obespechenie realizatsii strategiy adaptatsii [Organizational Support for Adaptation Strategy Implementation]. *Ekonomika: vchera, segodnya, zavtra* [Economics: Yesterday, Today, Tomorrow], 12(4-1), pp. 218-231.
13. Zavaleva E.V., Andruzskaya A.G., Zavalev V.I. (2023) Avtomatizirovannaya sistema prinyatiya upravlencheskikh resheniy [Automated Decision-Making System]. *ORGZDRA V: novosti, mneniya, obucheniya. Vestnik VSHOUZ* [ORGZDRA V: News, Opinions, Training. Bulletin of VSHOUZ], 9(3)(33), pp. 133-134.

-
14. Zhidko E.A., Kulikov A.N., Kozlov V.A. (2024) Ob intellektualnykh sistemakh podderzhki i prinyatiya resheniy [On Intelligent Decision Support Systems]. *Informatsionnye tekhnologii v stroitelnykh, sotsialnykh i ekonomicheskikh sistemakh* [Information Technologies in Construction, Social and Economic Systems], 1-2(31-32), pp. 28-32.
 15. Zueva A.N. (2024) Primenenie sistemnogo analiza dlya povysheniya effektivnosti upravlencheskikh resheniy v usloviyakh neopredelennosti [Application of System Analysis to Improve Efficiency of Management Decisions under Uncertainty]. *Sovremennaya nauka: aktualnye problemy teorii i praktiki. Seriya: Estestvennye i tekhnicheskie nauki* [Modern Science: Current Problems of Theory and Practice. Series: Natural and Technical Sciences], 4-2, pp. 70-76.