

ISSN 1999-4125 (Print)

ISSN 2949-0642 (Online)

Научная статья

УДК 622.23.05

DOI: 10.26730/1999-4125-2025-4-169-183

ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ УПРАВЛЕНИЯ НА ОТКРЫТЫХ ГОРНЫХ РАБОТАХ: СОСТОЯНИЕ И ПЕРСПЕКТИВЫ

Воронов Артем Юрьевич, Сыркин Илья Сергеевич, Пашков Дмитрий Алексеевич

Кузбасский государственный технический университет имени Т.Ф. Горбачева

* для корреспонденции: pashkovda@kuzstu.ru



Информация о статье

Поступила:

01 июня 2025 г.

Одобрена после

рецензирования:

22 июня 2025 г.

Принята к публикации:

30 июня 2025 г.

Опубликована:

28 августа 2025 г.

Ключевые слова:

открытые горные работы, система управления, искусственный интеллект, машинное обучение, SWOT-анализ.

Аннотация.

В настоящее время в области систем управления парками оборудования, являющимися важнейшей частью любого предприятия по добыче полезных ископаемых открытым способом, необходимо осуществить переход от традиционных к интеллектуальным системам из-за требований «Майнинга 4.0» и некоторых недостатков, присущих традиционным системам. Однако эта трансформация нуждается в техническом и стратегическом исследовании. Целесообразно изучить интеграцию интеллекта в карьерные системы управления по причине его значительного потенциала для повышения производительности, снижения затрат и повышения безопасности открытых горных работ. С этой целью были изучены ранее опубликованные исследования традиционных и интеллектуальных систем управления карьерами, чтобы зафиксировать их текущем состоянии. Выявлено, что основные факторы, параметры и цели оптимизации, наблюдаемые в существующих обычных СУ, позволяют сравнивать интеллектуальные СУ с их обычными аналогами. После этого базовые интеллектуальные модели сравнивались с точки зрения пяти категорий функций расстановки и диспетчеризации оборудования, что позволяет выявить игнорируемые технические пробелы. После определения направления будущих исследований используется популярный метод SWOT-анализа, позволяющий обрисовать сильные и слабые стороны, а также возможности и угрозы, связанные с появлением интеллектуальных систем управления на карьерах будущего. В целом анализ показывает, что преимущества перевешивают недостатки. Кроме этого, предлагаются возможные решения для устранения существующих недостатков и угроз. Также преследуются некоторые второстепенные цели, такие как временной анализ истории систем управления карьерами.

Для цитирования: Воронов А.Ю., Сыркин И.С., Пашков Д.А. Интеллектуальные системы управления на открытых горных работах: состояние и перспективы // Вестник Кузбасского государственного технического университета. 2025. № 4 (170). С. 169-183. DOI: 10.26730/1999-4125-2025-4-169-183, EDN: OKNUJR

Благодарности

Работа выполнена при финансовой поддержке Министерства науки и высшего образования Российской Федерации по соглашению от 30.09.2022 г. №075-15-2022-1198 с ФГБОУ ВО «Кузбасский государственный технический университет имени Т.Ф. Горбачева» Комплексной научно-технической программы полного инновационного цикла «Разработка и внедрение комплекса технологий в областях разведки и добычи твердых полезных ископаемых, обеспечения промышленной безопасности, биоремедиации, создания новых продуктов глубокой переработки из угольного сырья при последовательном снижении экологической нагрузки на окружающую среду и рисков для жизни населения» (КНТП «Чистый уголь – Зеленый Кузбасс»), утвержденной распоряжением Правительства

Российской Федерации от 11 мая 2022 г. № 1144-р в рамках реализации мероприятия «Разработка и создание беспилотного карьерного самосвала челночного типа грузоподъемностью 220 тонн» в части выполнения научно-исследовательских и опытно-конструкторских работ

Введение

Внедрение интеллекта в системы управления (СУ) погрузочно-транспортными работами на карьерах имеет огромное значение для развития отрасли. Интеллектуальные системы используют передовые технологии для оптимизации оперативного планирования, т. е. расстановки и диспетчеризации оборудования на время от 1 секунды до 1 дня. На технологические операции приходится более половины эксплуатационных затрат, треть общего объема потребляемой энергии и десятая часть мировых выбросов парниковых газов, связанных с энергетикой. Эти цифры подчеркивают значение СУ, хорошо зарекомендовавших себя на этапе эксплуатации, ведь даже небольшое изменение в погрузочно-транспортной системе может дать значительные экономические и экологические выгоды.

Поэтому целесообразно изучить интеграцию интеллекта в карьерные СУ по причине его значительного потенциала для повышения производительности, снижения затрат и повышения безопасности открытых горных работ. Техническое и стратегическое исследование может внести существенный вклад в выявление предварительных ошибок (например, игнорирование некоторых функций расстановки и диспетчеризации) в процессе формулирования предложенных на данный момент интеллектуальных СУ, а также в распознавание вероятных угроз и возможностей, связанных с ними. Это не только позволит в будущем разрабатывать более надежные интеллектуальные СУ, но и раскроет сильные и слабые стороны этих систем, помогая в их разработке.

СУ горными работами направлены на оптимизацию погрузочно-транспортных систем по одному или нескольким критериям путем принятия грамотных решений по расстановке и диспетчеризации с помощью компьютерных программ. В идеале СУ должна действовать автономно и связывать стратегические планы с операциями реального времени.

Динамическое распределение порожних карьерных самосвалов называется диспетчеризацией. Оно является противоположностью статическому распределению: самосвалы получают новое задание от СУ вместо того, чтобы обслуживать один экскаватор, что приводит к повышению производительности примерно на 10–15%. Самосвалы распределяются в двух основных систематических формах: одноуровневой и многоуровневой.

При одноуровневой форме без учета производственных планов задания выдаются на основе одного или нескольких эвристических принципов (критериев) диспетчеризации. Многоуровневый подход решает 3 последовательные подзадачи: 1) поиск кратчайшего пути; 2) оптимизация расстановки самосвалов по экскаваторам (маршрутам) – верхний уровень; 3) оптимизация назначений самосвалов в реальном времени (диспетчеризация) – нижний уровень. Как правило, на верхнем уровне устанавливается целевая выработка на маршрутах с учетом целей краткосрочного планирования. На нижнем уровне самосвалы распределяются по экскаваторам на основе оптимальных решений, полученных на верхнем уровне, как правило, с помощью эвристики или математических моделей.

Эти подходы были описаны во многих работах (например, [1–3]), и все авторы сходятся в одном: многоуровневый подход превосходит одноуровневый. Этот тезис был подтвержден и количественно в работе [2], где многоуровневая модель превзошла одноуровневую, на 60% увеличив среднюю выработку. Кроме того, одноуровневые системы имеют ограничения по отправке только одного самосвала за раз и игнорирования эксплуатационных требований, таких как требования к качеству сырья.

По другой классификации – в зависимости от уровня участия человека – СУ делятся на 3 основные категории: ручные, полуавтоматические и полностью автоматические.

Ручное управление подчиняется статическому принципу, по которому определенное количество самосвалов закрепляется за определенным экскаватором в течение всей смены. Эта система в значительной степени полагается на вмешательство человека, принимает решения на основе опыта и суждений и подвержена человеческим ошибкам. С другой стороны, она обеспечивает гибкость при адаптации к меняющимся условиям.

Полуавтоматическая система требует среднего уровня участия человека, при котором компьютеры играют роль в назначении самосвалов с использованием некоторых заранее определенных эвристических принципов или математических моделей. Тем не менее, за принятие окончательных решений отвечает человек. Хотя эта система снижает количество человеческих ошибок и повышает эксплуатационную эффективность по сравнению

с ручными системами, при крупных парках техники ее эффективность снижается.

В полностью автоматической системе технология контролирует и управляет без вмешательства человека. Эти системы оптимизируют операции, непрерывно анализируя данные, корректируя маршруты и максимизируя эффективность. Они обеспечивают повышенную производительность, снижение затрат и повышенную безопасность за счет сведения к минимуму человеческих ошибок и улучшения использования оборудования. Это представляет интерес для парадигмы «умной» горной добычи, инициированной 4-й промышленной революцией, когда «умные» карьеры стремятся включить полностью автоматические интеллектуальные СУ в свои задачи по переработке горной массы.

Концепция «Индустрии 4.0», возникшая в 2015 г., представляет собой смену парадигмы традиционных производственных процессов, основанную на взаимосвязанности, автоматизации, автономности, машинном обучении и данных в реальном времени. Можно определить «Майнинг 4.0», воплощение «Индустрии 4.0» в горнодобывающем секторе как цифровую революцию, направленную на привнесение интеллекта в традиционные операции по добыче полезных ископаемых с целью создания надежных и интеллектуальных систем. Ожидается, что эти системы обеспечат динамическую обработку, функциональную совместимость, автономность, мониторинг, оптимизацию, прогнозирование, принятие решений, виртуализацию и визуализацию. Эти функции достижимы за счет использования базовых технологий, таких как Интернет вещей, облачные вычисления, цифровые двойники, дополненная реальность и искусственный интеллект (ИИ) [4, 5].

Карьерные СУ как жизненно важные системы открытых горных работ должны развиваться с точки зрения встроенных технологий и архитектуры. В основном это связано не только со всей парадигмой «Майнинга 4.0», но и с некоторыми структурными недостатками, присущими традиционным методам. Эти две причины породили новую область исследований, известную как «интеллектуальные СУ», в рамках которой на данный момент проведено несколько исследований. Однако эти исследования имеют некоторые технические недостатки в постановке задач с точки зрения функций расстановки и диспетчеризации, такие как неучет целевых показателей качества сырья, питания обогатительной фабрики (ОФ) и состава сырья, ТО, отказов оборудования и т. д.

Выявление этих ошибок открывает путь для разработки более надежных систем. Этот восходящий анализ проводится с

использованием некоторых функций расстановки и диспетчеризации, собранных и классифицированных из ранее предложенных традиционных СУ, чтобы служить основой для технической оценки интеллектуальных СУ. Этот анализ предоставит дорожную карту для будущих направлений исследований в области карьерных СУ на основе ИИ. Вторая цель работы предполагает нисходящую позицию за счет использования инструмента стратегического анализа, называемого SWOT-анализом, чтобы выявить сильные и слабые стороны, возможности и угрозы, заслуживающие внимания при реализации интеллектуальных СУ на карьерах.

Технический анализ

В широкой перспективе СУ можно рассматривать как компонент логистики, который сам по себе входит в сферу управления цепочками поставок. СУ обычно описывается как разнообразный набор решений, касающихся различных аспектов транспортных операций, таких как ТО, расстановка, диспетчеризация и управление топливом.

Первое поколение карьерных СУ использовало ручное управление, которое опиралось на грубые методы, такие как двусторонняя радиосвязь, в 1960-х годах. Благодаря появлению телематики в 1980-х годах в СУ были включены технологии слежения за транспортными средствами. Однако они по-прежнему были ориентированы на человека. В том же десятилетии была создана знаменитая система «DISPATCH» [6] как инструмент, способный находить кратчайшие пути, а также размещать и распределять транспортные ресурсы. Это положило начало второму поколению карьерных СУ, построенных на математических моделях, симуляциях и метаэвристике (обычные СУ). Эти СУ разрабатывались в течение 4 десятилетий, и эта практика, видимо, будет продолжена и в будущем.

Хотя теория массового обслуживания (ТМО) была применена здесь в 1960-х годах [7], еще до введения математических моделей, ее влияние на карьерные СУ было ограниченным, и она не стала популярной. Примитивное исследование, проведенное в работе [8], можно назвать передовым исследованием интеллектуальных СУ, но в то время оно не получило большого признания. Тем не менее, это заложило основу для более авторитетных работ в 2020-х годах [9–11], что ознаменовало начало третьего поколения карьерных СУ, использующих технологии, предпочтительные для «Майнинга 4.0».

Парадигма «Майнинга 4.0» – не единственный фактор, способствующий появлению интеллектуальных СУ. Другой ключевой движущей силой перемен являются

недостатки обычных СУ, которые будут выявлены далее.

Обычные СУ

Обычные СУ в основном структурированы с использованием одного из 4 подходов: ТМО, математического программирования, имитационного моделирования и метаэвристики. В ТМО самосвал рассматривается как клиент, которому требуется услуга (погрузка). Если обслуживающий канал (экскаватор) недоступен, самосвал ожидает в очереди. Карьерные СУ обычно моделируются как задачи с несколькими каналами и множеством очередей с дисциплиной FIFO. Примитивная, но новаторская работа [7] по применению ТМО в системах карьерных перевозок была расширена другими исследователями годы спустя. Однако в настоящее время ТМО потеряла большую часть своей популярности из-за ограниченного спектра ее приложений. Теперь ее обычно интегрируют с многоуровневыми системами расстановки самосвалов на верхнем уровне, за которыми следует модель диспетчеризации на основе линейного программирования (ЛП) на нижнем уровне.

С развитием вычислительной мощности в 1980-х годах в карьерные СУ стали интегрировать методы математического программирования. ЛП и его варианты были основными методами решения задач как по расстановке, так и по диспетчеризации. Можно выделить работы по обычному ЛП [6], смешанному целочисленному ЛП, смешанному целочисленному целевому ЛП и нечеткому ЛП. Кроме того, в литературе присутствуют целевое, нелинейное и стохастическое программирование. Эволюция математических моделей достигла важной вехи: теперь это почти зрелые СУ, запрограммированные как многокритериальные модели, отражающие различные эксплуатационные требования, такие как минимизация расхода топлива, максимизация выработки и желаемый состав сырья для ОФ.

Этот уровень зрелости в некоторой степени обязан своим существованием имитационному моделированию (ИМ), инструменты которого позволили тестировать и проверять даже самые сложные математические модели на общедоступных устройствах, таких как ноутбуки. Дискретно-событийное ИМ, впервые внедренное в управление парками карьерного оборудования в 1960-х годах, часто применялось в качестве испытательного стенда для сравнения различных принципов диспетчеризации, выбора оборудования, его типоразмеров и прогнозирования отказов, причем ИМ не было самостоятельным инструментом оптимизации. Однако в 2010-х годах оно превратилось из дополнительного инструмента в важнейший элемент в основе математических моделей, внес

вклад в новое направление исследований, известное как модели оптимизации, интегрированные с ИМ.

Рассмотренные выше методы исследования операций обычно критикуют за необходимость учета множества эксплуатационных ограничений в погрузочно-транспортных системах. Однако это привлекло внимание некоторых исследователей к включению метаэвристических алгоритмов в расстановку и диспетчеризацию самосвалов без гарантии достижения оптимальных решений. Метаэвристики характеризуются простотой реализации и значительно сниженной вычислительной сложностью, тем самым приобретая первостепенное значение для СУ, которая требует быстрого принятия решений в реальном времени. Примеры: алгоритм муравьиной колонии, генетический алгоритм и империалистический конкурентный алгоритм диспетчеризации. Изучались и комбинации математического программирования и метаэвристики – например, применение смешанно-целочисленного программирования на верхнем уровне и табу-поиска на нижнем уровне.

Этот краткий обзор позволяет получить адекватные знания об основных вехах развития традиционных СУ, не отвлекаясь от целей текущей работы. Более подробные обзоры сделаны в работах [1, 3].

Традиционные методы играют ключевую роль в карьерных СУ на протяжении почти полувека. Многие ученые предприняли конструктивные усилия по теоретической и практической оптимизации этих систем. Этот уровень зрелости может послужить основой для реализации новых подходов, таких как СУ с поддержкой ИИ. Основные факторы, параметры и цели оптимизации, наблюдаемые в существующих обычных СУ, собраны и классифицированы в Таблице 1.

Эта таблица позволяет сравнить интеллектуальные СУ с их обычными аналогами, чтобы выявить потенциал для улучшения. Изучение компонентов, описанных в Таблице 1, показывает, что все эти компоненты можно свести к следующим 5 основным классам:

Класс 1: Добыча (план по добыче сырья, план по переработке сырья, коэффициент вскрыши, качество сырья, геологические неопределенности, приоритетность блоков, доступность рабочих фронтов).

Класс 2: Экскаваторы (разнотипность, масштабируемость, назначение, перемещение, отказы, плановое ТО, квалификация машиниста).

Класс 3: Самосвалы (разнотипность, масштабируемость, отказы, плановое ТО, расход топлива).

Класс 4: Эксплуатация (дорожные и погодные условия, маршрутизация, БВР).

Класс 5: Пункты назначения (мощность ОФ, сортность ОФ, мощность дробилок, мощность перегрузочных складов, требования к качеству на перегрузочных складах).

Несмотря на глубокую проработку, традиционные методы имеют ряд недостатков. ТМО, помимо ограниченной области применения, сталкивается с проблемами в неопределенных и сложных задачах. Математические методы испытывают проблемы с точки зрения сложности и времени выполнения, особенно в многорудных, многоучастковых карьерах со сложными эксплуатационными требованиями и неоднородными парками. Метаэвристические принципы часто применимы лишь к конкретным условиям, а при их изменении могут дать неоптимальные результаты. Еще одной важной особенностью, о которой часто забывают, является стохастичность, присущая большинству реальных задач.

Еще одно ограничение для традиционных методов относится к необходимости повторной оптимизации модели всякий раз, когда вносятся изменения в конфигурацию горнодобывающего комплекса. Наконец, традиционные методы часто используют централизованный подход; т. е. модель централизованного принятия решений выдает новое задание «нуждающемуся» самосвалу. Таким образом, обеспечение эффективной координации между экскаваторами

и самосвалами затруднено из-за образования очередей перед экскаваторами и дробилками, а также возникновения простоев экскаваторов.

Недостатки традиционных методов и потенциал альтернативных решений в сочетании с требованиями «Майнинга 4.0» побудили исследователей внедрить интеллект в карьерные СУ. Далее исследуются основы ИИ, а затем рассматриваются работы по внедрению интеллекта в карьерные СУ. Затем эти модели сравниваются со шкалой 5 классов, чтобы определить направления дальнейших исследований.

Интеллектуальные СУ

Представленный в середине XX века, ИИ прошел путь от обычного теста Тьюринга до новейших беспилотных автомобилей, которые сегодня можно увидеть на улицах. ИИ – это исследование того, как заставить компьютеры делать то, в чем люди на данный момент лучше. Достижение абстрактного мышления, принятия решений, адаптации к новой среде, творчества и социальных навыков является конечной целью общего ИИ.

Машинное обучение (МО), как основная часть ИИ, использует входные данные для достижения желаемой цели без буквального программирования; т. е. алгоритм автоматически изменяет свою архитектуру посредством процесса, называемого обучением, чтобы прогрессировать с возрастающим успехом в

Таблица 1. Основные компоненты оптимизации, отраженные в исследованиях по СУ

Table 1. The main components of optimization reflected in the studies on FMS

№	Категория	Компоненты
1	Факторы	1) Коэффициент вскрыши; 2) разнотипность оборудования; 3) интенсивность подачи сырья на ОФ; 4) основная сортность ОФ; 5) геологические неопределенности; 6) эксплуатационные неопределенности; 7) неопределенные отказы самосвалов; 8) плановое ТО; 9) масштабируемость; 10) связь с краткосрочными планами; 11) перемещение тяжелого оборудования; 12) заторы; 13) требования к смешиванию сортов сырья на перегрузочных складах; 14) назначение экскаваторов; 15) приоритетность блоков.
2	Параметры	1) Вместимость кузова самосвала; 2) вместимость ковша экскаватора; 3) скорость копания экскаватора; 4) интенсивность подачи сырья на ОФ; 5) основная сортность ОФ; 6) мощность дробилок; 7) вместимость пунктов разгрузки; 8) все типы времен (погрузка, транспортирование, маневрирование, разгрузка и т. д.); 9) оптимальный грузопоток от экскаватора до пункта разгрузки на основе решений верхнего уровня; 10) скорость груженого и порожнего самосвала; 11) характеристики и протяженность трасс; 12) использование самосвалов и экскаваторов; 13) качество различных элементов; 14) вертикальная и горизонтальная приоритетность блоков; 15) количество самосвалов и экскаваторов; 16) сравнительный фактор; 17) доступность рабочих фронтов.
3	Цели	1) Максимизировать выработку; 2) максимизировать использование самосвалов; 3) максимизировать использование экскаваторов; 4) максимизировать производительность экскаваторов; 5) минимизировать отклонение от требуемой интенсивности подачи сырья на ОФ; 6) минимизировать отклонение от основной сортности ОФ; 7) минимизировать затраты на эксплуатацию самосвалов; 8) минимизировать выбросы парниковых газов; 9) минимизировать пробеги; 10) минимизировать затраты на перемещение экскаваторов; 11) минимизировать суммарные простои экскаваторов; 12) минимизировать суммарные простои самосвалов; 13) минимизировать отклонение фактического грузопотока от желаемого.

достижении желаемой цели. МО делится на обучение с учителем (SL), обучение без учителя (USL) и обучение с подкреплением (RL). В SL доступны как обучающие, так и тестовые данные; модель обучается на основе помеченных данных для регрессии или классификации. USL – обучение модели с использованием немаркированной информации для кластеризации или ассоциации. Обучение в RL основано на методе проб и ошибок или опыте. Агент взаимодействует с окружающей средой, чтобы найти оптимальную политику, основанную на вознаграждениях и штрафах.

Общие методы МО включают линейный и нелинейный дискриминантный анализ, деревья решений, метод случайного леса (RF), метод k -ближайших соседей (kNN), метод опорных векторов (SVM), метод искусственных нейронных сетей (ANN), метод линейной регрессии, метод главных компонент (PCA) и Q -обучение. В составе ANN выделена специальная категория, называемая глубоким обучением (DL) когда человеческие агенты не имеют прямого вмешательства в процесс извлечения признаков из входных данных.

Для горных работ приложения МО можно в основном классифицировать как планирование производства, буровзрывные работы и управление оборудованием. Далее представлены некоторые из наиболее ярких работ за последние несколько лет.

Авторы работы [12] сравнили 6 методов МО для прогнозирования добычи на известняковом карьере с использованием Интернета вещей в качестве средства сбора данных; при этом модель SVM показала наиболее высокую производительность. 16 переменных (например, количество назначенных самосвалов, среднее время пробега) были выбраны и уменьшены по сравнению с первоначальными наблюдениями, чтобы служить входными переменными для прогнозирования выработки. Затем эффективность и точность методов МО сравнивались с использованием трех наборов проверочных данных. В более поздней работе те же авторы проводили прогнозирование, используя комбинацию алгоритма ястребов Харриса и SVM, прежде чем сравнивать его с RF и ANN. Алгоритм оптимизации продемонстрировал ключевую роль в повышении точности SVM, что привело к предложению об их интеграции в качестве наиболее совершенной интеллектуальной модели для прогнозирования выработки на карьерах.

Авторы работы [13] провели сравнение трех моделей (SVM, kNN и RF), чтобы спрогнозировать время движения самосвалов, тем самым минимизировав время цикла и распределив оптимизированное количество самосвалов на один экскаватор, используя

модель оптимизации ЛП. Данные о месторождении, собранные с помощью СУ в бокситовом карьере, а также климатические данные были использованы для обучения и тестирования моделей МО, где RF показал большую точность в прогнозировании времени пробегов.

Авторы работы [14] использовали SVM, kNN и RF для прогнозирования времени движения самосвалов в реальном времени, где SVM и RF были схожи по точности, и оба метода превосходили kNN. Характеристики самосвалов, дорог и погоды (всего 16) использовались в качестве входных данных для обучения. Эти данные были собраны из угольного разреза с помощью используемой на разрезе СУ и метеорологической службы.

Авторы работы [15] оптимизировали тип погрузочной машины и количество самосвалов, необходимых для обеспечения производительности ОФ, путем сравнения 5 алгоритмов, включая линейную регрессию, дерево решений, kNN, RF и алгоритм повышения градиента, причем последний был указан как наиболее точный, достигнув точности 85% в прогнозировании значений тестовых данных. Данные за 5 лет были собраны на каолиновом карьере и послужили исходными для обучения. Эти данные включают дату операции, погодные условия, время года, день недели, маршруты и типы погрузочных машин.

Хотя существует множество исторических данных, касающихся распределения самосвалов, эффективное использование таких данных для разработки оптимальной политики диспетчеризации представляет собой сложную задачу. Изменения в политике диспетчеризации оказывают глубокое влияние на будущую динамику заданий, что затрудняет методам SL распознавание и устранение этих динамических колебаний в реальном времени. Это особенно актуально в условиях горных работ, где определяющими являются многомерные динамические и стохастические события. Одной из основных причин, по которой методы SL и традиционные подходы неспособны эффективно решать динамические задачи, является централизованность этих методов. Эти методы имеют центральный блок для принятия решений по следующему диспетчерскому заданию, запрошенному самосвалом, в то время как децентрализация СУ путем определения проблемы как мультиагентной системы (MAS) представляется более эффективным решением.

MAS состоит из автономных агентов, которые взаимодействуют друг с другом, чтобы приспособиться к динамическим изменениям в рабочей среде. MAS обладают рядом фундаментальных свойств, таких как автономность, способность принимать решения

и самосознание, которые являются неотъемлемой частью их функционирования. В карьерных СУ, имеющих многочисленные самосвалы в качестве агентов, парадигма MAS использовалась в двух конфигурациях: договорное планирование и RL.

При договорном планировании агенты обозначают материальные объекты, такие как экскаваторы и самосвалы. Основной целью может быть выполнение производственного плана с минимальными затратами, что достигается за счет взаимодействия агентов. Они работают совместно и «договариваются» о составлении графиков для каждой отдельной единицы оборудования. Для этого используется механизм переговоров, такой как Contract Net Protocol (CNP) [16].

Агентов, участвующих в CNP, можно разделить на два основных типа: менеджеры (экскаваторы) и подрядчики (самосвалы). Роль менеджера заключается в мониторинге выполнения задач и обработке результатов, а подрядчик отвечает за практическое выполнение задач. Процесс начинается с менеджера, который инициирует переговоры, объявляя конкурс предложений подрядчикам. Подрядчики могут принять или отклонить предложение. Как только менеджер получает все предложения, он приступает к их оценке с помощью функции полезности, а затем отправляет сообщение о принятии соответствующему подрядчику. Одновременно он отправляет сообщение об отказе остальным подрядчикам, информируя их о своем решении. После этого самосвал, получивший сообщение о принятии, вместе с экскаватором, инициировавшим переговоры, обновляет свои расписания, включая диспетчерские задания, требующие выполнения. В конечном итоге самосвал берет на себя выполнение задания и затем уведомляет экскаватор о результате (неудаче или успехе) посредством информационного сообщения [16].

Авторы работы [17] предложили MAS с использованием CNP, в которой самосвалы, экскаваторы и пункты разгрузки как отдельные агенты взаимодействуют в общей среде карьера посредством обмена своими расписаниями в попытке достичь производственных целей с минимальными затратами. Сравнение модели MAS с централизованной системой, такой как «DISPATCH», снабжаемой фактическими данными, показало выполнение тех же объемов перевозок, но с меньшим временем пробега. Разработанная функция полезности поддерживает предложения со своевременным началом загрузки и наименьшим требуемым временем завершения. Однако работоспособность больших самосвалов остается неясной. При рассмотрении разнотипного парка самосвалов в горнотранспортной системе

меньшие по размеру самосвалы обычно ассоциируются с меньшим временем пробега. В некоторых сценариях функция полезности может отдавать предпочтение меньшим самосвалам перед более крупными, даже если предложение исходит от большого экскаватора, который лучше сочетается с большим самосвалом.

Авторы работы [18] включили поиск пути в свою структуру MAS, чтобы сократить количество агентов и оптимизировать процесс выбора наиболее подходящего агента для каждой диспетчерской задачи. Они оценили модель MAS, сравнив ее с ручной диспетчеризацией и жадным алгоритмом. Результаты оказались в пользу модели MAS с точки зрения достижения производственных целей и минимизации затрат на топливо.

Договорное планирование открывает новые двери в карьерных СУ, однако накладные расходы на связь, вызванные переговорами по поиску наилучшего расписания, приводят к увеличению времени решения по мере роста парка самосвалов. А MAS зависят от обмена информацией и сотрудничества между отдельными агентами для принятия решений. В системе диспетчеризации самосвалов агенты должны поддерживать постоянную связь, чтобы обмениваться подробностями о местонахождении самосвалов, их статусе и назначениях. Эта постоянная потребность в общении может привести к задержкам и неэффективности, особенно при больших масштабах горных работ. Однако эти расходы на связь не так уж значительны для агентов в СУ на основе RL, поскольку связь, если таковая имеется (это зависит от схемы обучения для агентов), существует на этапе обучения, а на этапе внедрения агенты действуют в режиме реального времени.

В RL агент пытается найти лучший путь для получения наивысшего вознаграждения. Фактически везде, где требуется найти оптимальный путь, появляется RL, будь то последовательность извлечения блоков при планировании производства или маршрутизация парка. Агент RL взаимодействует с моделируемой средой карьера и использует специальный алгоритм для оптимизации чистой приведенной стоимости горных работ. Цель агента может заключаться в максимизации выработки при одновременной минимизации затрат и соблюдении требований безопасности. Положительное вознаграждение можно отнести к желательным действиям, таким как добыча высококачественного сырья, достижение производственных показателей и демонстрация соблюдения правил безопасности. Диапазон возможных действий включает такие решения, как выбор последующего блока для извлечения или установление порядка извлечения, что

похоже на задачу определения оптимального маршрута при диспетчеризации карьерных самосвалов.

В сфере диспетчеризации с помощью RL термин «окружающая среда» относится к производственному контексту, в котором действует агент. Он включает в себя множество компонентов: планировку карьера, парк самосвалов, погрузочные площадки, подъездные пути, дорожные условия, ограничения безопасности и другие факторы, которые оказывают влияние на решения о назначении самосвалов. Среда характеризуется динамичностью и изменчивостью с течением времени. Она отражает реальные сложности и неопределенности, присущие горным работам, такие как различное количество самосвалов, отказы оборудования, заторы на дорогах и непредвиденные события. Сведения об окружающей среде встроены в вектор, к которому агент может получить доступ в любой момент.

Процесс, называемый «представлением состояния», влечет за собой определение способа представления текущего состояния системы. Это представление может включать в себя местоположение и статус отдельных самосвалов и экскаваторов, условия движения и другую информацию, которая влияет на диспетчерские решения, принимаемые на основе заранее определенного пространства действий. Пространство действий включает в себя все решения по назначению в разные пункты или из них (пункты погрузки, отвалы, склады и ОФ). Правильное диспетчерское решение (оптимальная политика) в каждом состоянии изучается агентом в результате сигналов вознаграждения, которые он получает в качестве обратной связи от среды. Функция вознаграждения предназначена для поощрения выгодных заданий при назначении самосвалов и должна соответствовать установленным целям и ограничениям. Цели могут быть такие: минимизация эксплуатационных расходов, минимизация простоев самосвалов, максимизация выработки и удовлетворение требований ОФ по интенсивности и качеству потока сырья. Положительные вознаграждения назначаются за качественное выполнение задач, а отрицательные вознаграждения (штрафы) налагаются за задержки, неправильные задания или нежелательные результаты.

Определив основные компоненты задачи управления на основе RL, можно выбрать подходящий алгоритм для обучения агента. Алгоритмы, основанные на моделях, зависят от построения или изучения функций перехода, представляющих динамику окружающей среды. Алгоритмы без моделей напрямую приобретают функции ценности или политики на основе

опыта, не требуя знания базовой динамики. Это делает безмодельные алгоритмы хорошо подходящими для решения проблемы диспетчеризации в динамичной и развивающейся горнодобывающей среде. Безмодельные алгоритмы RL можно разделить на 3 типа: алгоритмы, основанные на полезности, на политиках и на критике субъектов.

Алгоритмы, основанные на полезности, направлены на оценку функции полезности, которая отражает ожидаемую отдачу или полезность пребывания в данном состоянии или выполнения определенного действия. Они напрямую оценивают и пересматривают значения, связанные с состояниями или парами «состояние-действие». Алгоритмы, основанные на политиках, напрямую изучают политики, которые устанавливают взаимосвязь между состояниями и действиями, без явной оценки функций полезности. Они исследуют различные политики, чтобы найти ту, что максимизирует ожидаемое совокупное вознаграждение. Алгоритмы «субъект-критик» объединяют аспекты двух предыдущих методов, используя два компонента: субъект, ответственный за изучение политики, и критик, ответственный за оценку функции полезности. Субъект предлагает действия, основанные на изученной политике, а критик оценивает предлагаемые действия, оценивая их полезность.

Выбор подходящего алгоритма зависит от особенностей пространств состояний и действий. В задаче диспетчеризации самосвалов, для которой характерны конечные и дискретные пространства действий, алгоритмы, основанные на полезности, предпочтительнее алгоритмов, основанных на политиках, характеризующихся бесконечными и непрерывными пространствами действий. Поэтому большинство СУ на основе RL, разработанных до сих пор, используют алгоритмы, основанные на полезности [9–11].

Одними из первых применили агентный подход к управлению ЭАК карьеров авторы работы [8]; они предложили подход с одним агентом, основанный на марковских процессах принятия решений, зависящих от времени. Сравнение модели с двумя эвристиками в симуляторе дискретных событий показало превосходство в объемах перевозок.

Авторы работы [11] предложили сеть обмена опытом для динамического распределения самосвалов с учетом таких ограничений, как вместимость самосвалов, ожидаемое время простоя, общая вместимость ожидающих самосвалов, время активности и вместимость задержанных самосвалов. Модель была протестирована на основе двух эвристик диспетчеризации в событийном симуляторе, что привело к повышению производительности более чем на 5%. Функция вознаграждения

определялась как отношение вместимости самосвала ко времени, необходимому для выполнения диспетчерского действия. Авторы обучили свою сеть для 50 самосвалов, а затем исследовали надежность модели в случае поломки самосвалов или добавления новых самосвалов в грузовой автопарк. Модель продемонстрировала способность до определенной степени справляться с масштабируемостью самосвалов без переобучения. Несмотря на креативность модели, влияние последующих агрегатов, таких как дробилки или ОФ, было проигнорировано.

Авторы работы [10] объединили дискретно-событийную модель с нейросетью. Симулятор имитирует оперативное взаимодействие между экскаваторами, самосвалами и пунктами разгрузки, чтобы создать вектор входных данных, таких как размеры очередей, доступность, время простоя, требования к дробилке/фабрике и прошлый опыт. Эти параметры вместе с функцией вознаграждения используются для генерации опыта и обучения сети для будущих заданий самосвалов. Модель превзошла две схемы диспетчеризации на медно-золотодобывающем комплексе по показателям извлечения руды, суточной производительности ОФ и размера очередей. Модель учитывала возможную неоднородность парков (как экскаваторов, так и самосвалов), отказы техники, мощности ОФ и геологическую неопределенность. Однако изменения в последовательности извлечения блоков, пунктах назначения и размере парка требуют 4-часового

переобучения.

Авторы работы [9] предложили интеллектуальную СУ на базе RL с целью минимизации выбросов парниковых газов на открытых горных работах. В своем мультиагентном алгоритме они уделили внимание плановому и внеплановому ТО. Модель сравнивалась с двумя эталонными диспетчерскими решениями (фиксированное распределение и планирование) в симуляторе. Управление на основе RL снизило выбросы на единицу продукции более чем на 30%. Оно также превзошло эталонное решение почти на треть по производительности автопарка и эффективности расхода топлива. Модель направлена на максимизацию точных поставок (транспортировка руды на ОФ или вскрыши на отвал), тем самым минимизируя расход топлива и выбросы. Расход топлива минимизируется за счет более эффективных диспетчерских решений, минимизирующих «неправильные» перевозки. Однако авторы предположили, что автопарк однороден и имеет небольшие размеры. Более того, определенный вектор состояния включает в себя небольшое количество переменных принятия решений. Участие перерабатывающих предприятий также не было учтено.

Теперь сравним перечисленные работы с точки зрения 5 признаков, выделенных ранее. В работах по договорному планированию, [17] и [18], исследовались схожие особенности, кроме отказов самосвалов и расхода топлива, которые отдельно изучаются в каждой работе. Однако эти



два исследования не учли ни одну особенность класса пунктов назначения. Положительным моментом является то, что в обеих работах рассматривались целевые объемы добычи сырья, поскольку договорные системы должны быть снабжены производственным планом, чтобы создать необходимые графики. Работы, основанные на RL, не затрагивали этот аспект и были сосредоточены на других функциях. В частности, в работе [9] уделено внимание расходу топлива и плановому ТО, отличившись как единственная работа на основе RL, учитывающая эти две особенности. Авторы работы [10] учли больше функций, включая неопределенность качества сырья, целевые объемы переработки, отказы экскаваторов, мощность ОФ и мощность дробилок (всего 9 функций), что вывело их в лидеры по количеству рассматриваемых характеристик. Эта цифра почти в 4 раза превосходит работу [8] как систему с наименьшим количеством учтенных функций.

Таким образом, многие функции из шкалы 5 классов в существующих интеллектуальных СУ игнорируются: добыча (коэффициент вскрыши, приоритет блоков), экскаваторы (масштабируемость, время перемещения, плановое ТО), эксплуатация (заторы, погодные условия, БВР) и пункты назначения (основная сортность ОФ, вместимость складов и требования по качеству). Игнорируется почти половина желательных функций, что подчеркивает необходимость дальнейших исследований интеллектуальных СУ.

Стратегический анализ

SWOT-анализ является популярным механизмом оценки внутренних (контролируемых, сильных и слабых сторон) и внешних (неконтролируемых, возможностей и угроз) факторов, влияющих на организацию, в попытке следовать методическому подходу при принятии решений. Сильные стороны определяют, в каких областях организация преуспевает и что отличает ее от конкурентов. Слабые стороны заставляют организацию функционировать неоптимальным образом, и их изменение имеет большое значение для того, чтобы остаться на рынке. Возможности – внешние факторы, которые могут создать конкурентное преимущество; ими можно воспользоваться или инвестировать в них. Угрозы – внешние факторы, которые могут нанести вред организации и помешать ее успеху. Эти 4 элемента визуализируются в сетке 2×2, чтобы четко обозначить плюсы и минусы проекта. SWOT-диаграмма для анализа интеллектуальных СУ на карьерах изображена на Рис. 1.

Сильные стороны (Strengths). Основное преимущество алгоритмов RL заключается в их

способности учитывать динамичность горных работ. Агент RL, прошедший адекватную подготовку методом проб и ошибок, может быстро справиться с изменениями в среде, подготавливая ее к изменениям в реальном времени. Агент обучается, например, более чем 10 000 эпизодов, приобретая опыт работы с различными неопределенностями.

Еще одна сильная сторона этих методов – способность эффективно решать крупномасштабные задачи. Основываясь только на методологии решения задач, они уменьшают вычислительную сложность и время решения за счет поиска почти оптимальных решений. Эти алгоритмы также способны поддерживать свою эффективность без необходимости полного пересмотра всей модели из-за незначительных изменений в среде карьера. Агент берет на себя роль интеллектуального лица, принимающего решения и обладающего самосознанием, таким образом хорошо справляясь с изменениями в среде.

Кроме того, агенты RL демонстрируют впечатляющий уровень автономности. Они способны получать информацию из своего окружения и автономно принимать решения, без четких инструкций или постоянного вмешательства человека. Используя прошлый опыт и исследования методом проб и ошибок, они могут принимать оптимальные решения, не полагаясь на диспетчеров. В целом RL способствует динамическому управлению, быстрому принятию решений, универсальности и автономности в карьерных СУ.

Слабые стороны (Weaknesses).

Использование RL может быть затруднено аппаратными ограничениями, такими как ограниченные вычислительные ресурсы, объем памяти, задержка связи и ограничения окружающей среды. Алгоритмы RL требуют значительных вычислительных мощностей, особенно когда они сталкиваются с обширными пространствами состояний и действий. Кроме того, некоторые резкие изменения в динамике среды карьера могут повлечь за собой переподготовку алгоритма диспетчеризации.

Решение этой проблемы предполагает оптимизацию реализации алгоритмов RL для повышения их вычислительной эффективности. Для облегчения вычислительной нагрузки можно использовать такие методы, как распараллеливание и распределение. Использование облачных вычислений или специализированного оборудования также потенциально может повысить производительность. Требования к оборудованию для RL зависят от конкретной задачи и желаемых показателей производительности, что вызывает необходимость вдумчивой оценки

вычислительных требований, присущих исследуемой проблеме.

На карьерах могут возникнуть существенные задержки связи между агентом RL и самосвалами из-за большого расстояния, разделяющего центр управления и самосвалы. Чтобы смягчить последствия задержки связи, можно реализовать децентрализованный подход: отдельные самосвалы могут действовать как автономные агенты, принимая локализованные решения, основанные на их непосредственном окружении. Эти локальные агенты могут периодически связываться с центральным сервером для синхронизации своих знаний и обновления глобальной информации. Приняв этот подход, можно уменьшить негативное влияние задержек, способствуя более своевременному принятию решений.

Помимо проблем с «железом» теоретическая база ИИ, особенно RL, на данный момент не особенно развита и дает множество возможностей для совершенствования.

Возможности (Opportunities). В экономическом аспекте интеллектуальные СУ обладают потенциалом снижения затрат за счет повышения эксплуатационной производительности и уровня производства. Таким образом, экономический аспект переплетается с производственным и эксплуатационным. Агенты RL, принимая во внимание различные факторы, способны принимать интеллектуальные решения в реальном времени. Это способствует оптимальной маршрутизации самосвалов, сокращению простоев и повышению эксплуатационной производительности, что в конечном итоге приводит к экономии.

Внедряя интеллектуальные технологии в карьерные СУ, можно эффективно снизить расход топлива, тем самым эффективно снижая общие эксплуатационные расходы на добычу полезных ископаемых. Это преимущество не только способствует снижению затрат, но и согласуется с усилиями по обеспечению экологической устойчивости за счет минимизации углеродного следа, связанного с эксплуатацией карьерных самосвалов.

Графики ТО самосвалов также могут быть оптимизированы. Тщательно изучая данные датчиков и исторические записи ТО, интеллектуальные алгоритмы способны прогнозировать наиболее выгодные интервалы ТО для каждого самосвала. Это помогает предотвратить поломки, уменьшает количество незапланированных простоев, тем самым обеспечивая бесперебойную работу парка самосвалов, максимизируя эксплуатационную производительность и способствуя общему снижению затрат на карьере.

Кроме того, интеллектуализация карьерных СУ позволяет разрабатывать модели принятия решений, придающих значение безопасности при назначении самосвалов. Эти системы способны получать знания, касающиеся аспектов, связанных с безопасностью (например, близости к другим ТС, поведения водителя, дорожных условий, погодных условий и потенциальных дефектов ТС) в процессе принятия решений. Это способствует снижению потенциальных рисков, связанных с несчастными случаями и травмами.

Еще одна возможность – это культура производства. Чем меньше человеческого взаимодействия происходит на рабочей площадке, тем меньше будет конфликтов. Интеллектуальные СУ обладают потенциалом для формирования позитивной культуры производства благодаря способности оптимизировать рабочие процессы, снижать стресс сотрудников и способствовать улучшению коммуникации между различными командами.

Угрозы (Threats). С точки зрения инфраструктуры проблемы возникают из-за ограниченных возможностей подключения, устаревших технологий или неадекватных сенсорных сетей. Одно из возможных решений – улучшение инфраструктуры предприятий путем внедрения надежных беспроводных сетей или технологий Интернета вещей. Это обеспечивает плавный обмен данными между самосвалами, датчиками и СУ.

Недостаточные или некачественные данные о движении самосвалов, дорожных условиях или состоянии оборудования могут повлиять на эффективность алгоритмов обучения. Решением является внедрение надежных средств сбора данных с использованием датчиков, GPS или телематических устройств для получения надежной информации.

Также могут возникнуть проблемы, связанные с нарушением правил безопасности и требований законодательства. Решение заключается в налаживании сотрудничества с регулирующими органами и экспертами по правовым вопросам для понимания и интеграции соответствующих руководств по безопасности и соблюдению требований в систему.

Другая угроза заключается в сопротивлении заинтересованных сторон, включая акционеров, менеджеров и горняков. Обеспокоенность по поводу безопасности рабочих мест, отсутствие доверия к автоматизации и понимание того, что технологии заменяют людей, могут помешать внедрению. Решение заключается в повышении осведомленности о возможностях, предлагаемых интеллектуальными СУ, и подчеркивании их способности расширять человеческие возможности, а не заменять собой рабочих. Анализ цепочки создания стоимости также

может оказаться полезным, поскольку он проливает свет на добавленную стоимость, которую такие системы могут принести акционерам и менеджерам.

Здесь возникает другая угроза – инвестиционная ценность или прибыльность. Значительные первоначальные затраты, ограниченный бюджет и неопределенные выгоды могут стать препятствиями внедрению интеллекта. Одно из возможных решений предполагает проведение комплексного анализа затрат и выгод, чтобы проиллюстрировать среднесрочные и долгосрочные финансовые выгоды, связанные с интеллектуальными СУ.

Последняя угроза заключается в уязвимости интеллектуальных систем к кибератакам, приводящим к сбоям в работе, утечке данных и потенциальному вреду и персоналу, и оборудованию. Необходимо создать надежную систему кибербезопасности и придерживаться лучших отраслевых практик. Это предполагает проведение регулярных оценок безопасности и постоянного мониторинга, разработку протоколов реагирования на инциденты и своевременные обновления программного обеспечения для устранения возникающих уязвимостей.

На Рис. 1 показаны компоненты SWOT-анализа в двух общих классификациях: внутренний/внешний и положительный/негативный. Внутренние факторы (сильные и слабые стороны) коррелируют с внутренними особенностями интеллектуальных СУ (например, алгоритмами и аппаратными средствами), тогда как внешние факторы (возможности и угрозы) учитывают конструктивные и разрушительные силы, действующие извне. Количество внутренних и внешних факторов – 6 и 11 соответственно, что указывает на то, что внедрение интеллектуальных СУ преимущественно определяется внешними факторами. Количество угроз и возможностей почти одинаково, однако угрозы можно устранить с помощью рекомендованных решений. С другой точки зрения, эти 4 компонента можно разделить на отрицательные (слабые стороны и угрозы) и положительные (сильные стороны и возможности). Число отрицательных и положительных элементов – 7 и 10 соответственно, т. е. положительных сторон больше, чем отрицательных. В целом очевидно, что при внедрении интеллектуальных СУ преимущества перевешивают недостатки.

Обсуждение результатов

СУ сыграли решающую роль в революционном изменении качества работы карьеров. В развитии этих систем были достигнуты заметные успехи, предоставляющие горнодобывающим компаниям возможность

максимально эффективно использовать парк горных машин, оптимизировать рабочие процессы и повысить общую производительность.

На ранних этапах надзор за технологическими парками в значительной степени опирался на трудоемкие методы отслеживания и связи, что приводило к неэффективности и несвоевременным перерывам. Чтобы решить эти проблемы, в 1980-х годах появилось второе поколение карьерных СУ, известных как обычные, которые использовали преимущества компьютеров для целей расстановки и диспетчеризации с использованием методов исследования операций, метаэвристики и математического моделирования.

Хотя обычные СУ были актуальны в течение почти полувека, они, несмотря на свою зрелость, постепенно уступают место третьему поколению – интеллектуальным СУ. Этому сдвигу парадигмы способствуют два фактора: 1) требования «Майнинга 4.0» в отношении автономности, динамизма управления и принятия решений на всех операционных уровнях; 2) структурные недостатки, присущие традиционным моделям.

Интеллектуальные СУ, особенно на базе RL, обладают впечатляющими возможностями управления и адаптации к динамичности. Благодаря обучению в ходе многочисленных итераций алгоритмы RL знакомят агентов с различными неопределенностями и динамическими сценариями, предоставляя им расширенные возможности эффективного реагирования на динамические среды. В отличие от традиционных систем агенты, обученные с помощью алгоритмов RL, демонстрируют способность ориентироваться в этой постоянно меняющейся динамике, что исторически считалось сложной задачей. Умение интеллектуальных СУ справляться с динамичностью приводит к смене парадигмы, повышая эксплуатационную производительность на карьерах.

Научные исследования в данной области имеют некоторые недостатки, связанные с особенностями расстановки и диспетчеризации. Чтобы подчеркнуть эти недостатки, предложена шкала из 5 классов функций, вдохновленная исследованием обычных СУ. Наложение этой шкалы на уже разработанные интеллектуальные СУ показало, что почти половина желательных функций шкалы в этих системах игнорируется. Она проводит линию исследований для разработки более надежных интеллектуальных СУ в будущем.

В дополнение к этому восходящему анализу использован нисходящий подход, чтобы отобразить общую картину возможности

реализации интеллектуальных СУ. SWOT-анализ выявил сильные и слабые стороны, возможности и угрозы, связанные с внедрением интеллекта в горнодобывающие СУ. Слабые стороны и угрозы преодолимы с помощью предложенных решений. Используя потенциальные возможности, которые могут предложить интеллектуальные СУ, можно устранить основные угрозы. В целом баланс факторов на SWOT-диаграмме больше склоняется в пользу интеллектуальных СУ. Подводя итог, можно сказать, что это исследование подтверждает необходимость интеллектуальных СУ на карьерах – как с технической, так и со стратегической точки зрения.

Выводы

Системы управления горнодобывающим предприятием позволили эффективно использовать парк горной техники за счет оптимизации рабочих процессов.

Развитие СУ карьерным транспортом на карьерах в настоящее время представлено третьим поколением. Первое поколение СУ продолжалась до 1980-х годов, второе продолжалось до 2020-х годов.

Обычные СУ уступают место третьему поколению за счет двух факторов: 1) требований «Майнинга 4.0» в отношении автономности, динамизма управления и принятия решений на всех операционных уровнях; 2) структурных недостатков, присущих традиционным моделям.

Существует необходимость применения интеллектуальных систем управления на предприятиях, добывающих полезные ископаемые открытым способом.

СПИСОК ЛИТЕРАТУРЫ

1. Alarie S., Gamache M. Overview of solution strategies used in truck dispatching systems for open pit mines // International Journal of Surface Mining, Reclamation and Environment. 2002. № 16(1). Pp. 59–76.
2. Chaowasakoo P., Seppala H., Koivo H., Zhou Q. Digitalization of mine operations: scenarios to benefit in real-time truck dispatching // International Journal of Mining Science and Technology. 2017. № 27(2). Pp. 229–236.
3. Afrapoli A. M., Askari-Nasab H. Mining fleet management systems: a review of models and algorithms // International Journal of Mining, Reclamation and Environment. 2019. № 33(1). Pp. 42–60.
4. Чехлар М., Жиронкин С. А., Жиронкина О. В. Цифровые технологии Индустрии 4.0 в Майнинге 4.0 – перспективы развития геотехнологии в XXI веке // Вестник КузГТУ. 2020. № 3. С. 80–90.
5. Жиронкина О. В. Становление Майнинга 4.0 как отраслевой инновационной технологической платформы Индустрии 4.0 в свете достижения технологического суверенитета // Экономика и © 2025 Авторы. Эта статья доступна по лицензии Creative Commons «Attribution» («Атрибуция») 4.0 Всемирная (<https://creativecommons.org/licenses/by/4.0/>)
- управление инновациями. 2022. № 3(22). С. 60–77.
6. White J. W., Olson J. P. Computer-based dispatching in mines with concurrent operating objectives // Mining Engineering. 1986. № 38(11). Pp. 1045–1054.
7. Koenigsberg E. Finite queues and cyclic queues // Operational Research. 1960. № 8(2). Pp. 246–253.
8. Bastos G. S., Souza L. E., Ramos F. T., Ribeiro C. H. A single-dependent agent approach for stochastic time-dependent truck dispatching in open-pit mining // In: Proceedings of the 2011 IEEE International Intelligent Transportation Systems Conference (ITSC). 2011. Pp. 1057–1062.
9. Huo D., Sari Y.A., Kealey R., Zhang Q. Reinforcement learning-based fleet dispatching for greenhouse gas emission reduction in open-pit mining operations // Resources, Conservation and Recycling. 2023. № 188. 106664.
10. De Carvalho J.P., Dimitrakopoulos R. Integrating production planning with truck-dispatching decisions through reinforcement learning while managing uncertainty // Minerals. 2021. № 11.
11. Zhang C., Odonkor P., Zheng S., Khorasgani H., Serita S., Gupta C., Wang H. Dynamic dispatching for large-scale heterogeneous fleet via multi-agent deep reinforcement learning // In: Proceedings of the 2020 IEEE International Conference on Big Data (Big Data). 2020. Pp. 1436–1441.
12. Choi Y., Nguyen H., Bui X.-N., Nguyen-Thoi T., Park S. Estimating ore production in open-pit mines using various machine learning algorithms based on a truck-haulage system and support of internet of things // Natural Resources Research. 2021. № 30(2). Pp. 1141–1173.
13. Choudhury S., Naik H. Use of machine learning algorithm models to optimize the fleet management system in opencast mines // In: Proceedings of the 2022 IEEE International Conference for Convergence in Technology (I2CT). 2022. Pp. 1–8.
14. Sun X., Zhang H., Tian F., Yang L. The use of a machine learning method to predict the real-time link travel time of open-pit trucks // Mathematical Problems in Engineering. 2018.
15. Nobahar P., Pourrahimian Y., Mollaei K.F. Optimum fleet selection using machine learning algorithms – case study: Zenouz Kaolin mine // Mining, 2022, no 2(3), pp. 528–541.
16. Smith R.G. The contract net protocol: High-level communication and control in a distributed problem solver // IEEE Transactions on Computers. 1980. № 29(12). Pp. 1104–1113.
17. Icarte Ahumada G., Diaz Pinto J., Herzog O. A dynamic scheduling multiagent system for truck dispatching in open-pit mines // In: International Conference on Agents and Artificial Intelligence. 2021. Pp. 132–148.
18. Cohen M.W., Coelho V.N. Open-pit mining operational planning using multi agent systems // Procedia Computer Science. 2021. № 192. Pp. 1677–1686.
19. Hazrathosseini A., Afrapoli A.M. Intelligent fleet management systems in surface mining: status, threats, and opportunities // Mining, Metallurgy & Exploration. 2023.

Авторы заявляют об отсутствии конфликта интересов.

Об авторах:

Воронов Артем Юрьевич – кандидат технических наук, доцент, г. Кемерово, Российская Федерация, Кузбасский государственный технический университет им. Т. Ф. Горбачева.

Сыркин Илья Сергеевич – кандидат технических наук, г. Кемерово, Российская Федерация, Кузбасский государственный технический университет им. Т. Ф. Горбачева.

Пашков Дмитрий Алексеевич – кандидат технических наук, г. Кемерово, Российская Федерация, Кузбасский государственный технический университет им. Т. Ф. Горбачева; e-mail: pashkovda@kuzstu.ru

Заявленный вклад авторов:

Воронов Артем Юрьевич – постановка исследовательской задачи, обзор соответствующей литературы, концептуализация исследования, сбор и анализ данных, написание текста.

Сыркин Илья Сергеевич – постановка исследовательской задачи, обзор соответствующей литературы, сбор и анализ данных, написание текста.

Пашков Дмитрий Алексеевич – научный менеджмент, концептуализация исследования, выводы, написание текста.

Все авторы прочитали и одобрили окончательный вариант рукописи.

Original article

INTELLIGENT FLEET MANAGEMENT SYSTEMS IN OPEN-PIT MINING: STATUS AND PROSPECTS

Artem Yu. Voronov, Ilya S. Syrkin,
Dmitry A. Pashkov

T.F. Gorbachev Kuzbass State Technical University

* for correspondence: pashkovda@kuzstu.ru



Article info

Received:

01 June 2025

Accepted for publication:

22 June 2025

Accepted:

30 June 2025

Published:

28 August 2025

Keywords: open-pit mining, fleet management system, artificial intelligence, machine learning, SWOT analysis

Abstract.

Currently, in the field of equipment fleet management systems, which are an essential part of any open-pit mining enterprise, it is necessary to make the transition from traditional to intelligent systems due to the requirements of "Mining 4.0" and some of the disadvantages inherent in the traditional system. However, this transformation needs technical and strategic research. It is advisable to explore the integration of intelligence into career management systems because of its significant potential to increase productivity, reduce costs, and enhance the safety of open-pit mining. To this end, previously published studies of traditional and intelligent career management systems were studied in order to capture their current state. It is revealed that the main factors, parameters and optimization goals observed in existing conventional control systems make it possible to compare intelligent control systems with their conventional counterparts. After that, the basic intelligent models were compared in terms of five categories of equipment placement and dispatching functions, which makes it possible to identify ignored technical gaps. After determining the direction of future research, a popular SWOT analysis method is used to outline the strengths and weaknesses, as well as the opportunities and threats associated with the emergence of intelligent management systems in the careers of the future. Overall, the analysis shows that the advantages outweigh the disadvantages. In addition, possible solutions are proposed to eliminate existing shortcomings and threats. Some secondary goals are also pursued, such as a time-based analysis of the history of career management systems.

For citation: Voronov A.Yu., Syrkin I.S., Pashkov D.A. Intelligent fleet management systems in open-pit mining: status and prospects. *Vestnik Kuzbasskogo gosudarstvennogo tekhnicheskogo universiteta*=Bulletin of the Kuzbass State Technical University. 2025; 4(170):169-183. (In Russ., abstract in Eng.). DOI: 10.26730/1999-4125-2025-4-169-183, EDN: OKNUJR

Acknowledgments

The work was carried out with the financial support of the Ministry of Science and Higher Education of the Russian Federation under the agreement dated 30.09.2022 №075-15-2022-1198 with the Kuzbass State Technical University named after T.F. Gorbachev's "Comprehensive scientific and technical program for a full innovation cycle "Development and implementation of a set of technologies in the fields of exploration and extraction of solid minerals, industrial safety,

bioremediation, creation of new products of deep processing from coal raw materials while consistently reducing the environmental impact and risks to the life of the population" (CSTP "Clean coal – Green Kuzbass") approved by the decree of the Government of the Russian Federation dated May 11, 2022. No. 1144-r within the framework of the event "Development and creation of an unmanned shuttle-type mining dump truck with a lifting capacity of 220 tons" in terms of research and development work

REFERENCES

1. Alarie S., Gamache M. Overview of solution strategies used in truck dispatching systems for open pit mines. *International Journal of Surface Mining, Reclamation and Environment*. 2002; 16(1):59–76.
2. Chaowasakoo P., Seppala H., Koivo H., Zhou Q. Digitalization of mine operations: scenarios to benefit in real-time truck dispatching. *International Journal of Mining Science and Technology*. 2017; 27(2):229–236.
3. Afrapoli A.M., Askari-Nasab H. Mining fleet management systems: a review of models and algorithms. *International Journal of Mining, Reclamation and Environment*. 2019; 33(1):42–60.
4. Cehlar M., Zhironkin S.A., Zhironkina O.V. Digital technologies of Industry 4.0 in Mining 4.0 – prospects for the development of geotechnology in the XXI century. *Vestnik KuzGTU*. 2020; 3:80–90. [In Russ]
5. Zhironkina O.V. Establishment of Mining 4.0 as an industry innovative technological platform of Industry 4.0 in the light of achieving technological sovereignty. *Economics and Innovation Management*. 2022; 3(22):60–77. [In Russ]
6. White J.W., Olson J.P. Computer-based dispatching in mines with concurrent operating objectives. *Mining Engineering*. 1986; 38(11):1045–1054.
7. Koenigsberg E. Finite queues and cyclic queues. *Operational Research*. 1960; 8(2):246–253.
8. Bastos G.S., Souza L.E., Ramos F.T., Ribeiro C.H. A single-dependent agent approach for stochastic time-dependent truck dispatching in open-pit mining. In: *Proceedings of the 2011 IEEE International Intelligent Transportation Systems Conference (ITSC)*. 2011. Pp. 1057–1062.
9. Huo D., Sari Y.A., Kealey R., Zhang Q. Reinforcement learning-based fleet dispatching for greenhouse gas emission reduction in open-pit mining operations. *Resources, Conservation and Recycling*. 2023; 188:106664.
10. De Carvalho J.P., Dimitrakopoulos R. Integrating production planning with truck-dispatching decisions through reinforcement learning while managing uncertainty. *Minerals*. 2021; 11.
11. Zhang C., Odonkor P., Zheng S., Khorasgani H., Serita S., Gupta C., Wang H. Dynamic dispatching for large-scale heterogeneous fleet via multi-agent deep reinforcement learning. In: *Proceedings of the 2020 IEEE International Conference on Big Data (Big Data)*. 2020. Pp. 1436–1441.
12. Choi Y., Nguyen H., Bui X.-N., Nguyen-Thoi T., Park S. Estimating ore production in open-pit mines using various machine learning algorithms based on a truck-haulage system and support of internet of things. *Natural Resources Research*. 2021; 30(2):1141–1173.
13. Choudhury S., Naik H. Use of machine learning algorithm models to optimize the fleet management system in opencast mines. In: *Proceedings of the 2022 IEEE International Conference for Convergence in Technology (I2CT)*. 2022. Pp. 1–8.
14. Sun X., Zhang H., Tian F., Yang L. The use of a machine learning method to predict the real-time link travel time of open-pit trucks. *Mathematical Problems in Engineering*. 2018.
15. Nobahar P., Pourrahimian Y., Mollaei K.F. Optimum fleet selection using machine learning algorithms – case study: Zenouz Kaolin mine. *Mining*, 2022, no 2(3), pp. 528–541.
16. Smith R.G. The contract net protocol: High-level communication and control in a distributed problem solver. *IEEE Transactions on Computers*. 1980; 29(12):1104–1113.
17. Icarte Ahumada G., Diaz Pinto J., Herzog O. A dynamic scheduling multiagent system for truck dispatching in open-pit mines. In: *International Conference on Agents and Artificial Intelligence*. 2021. Pp. 132–148.
18. Cohen M.W., Coelho V.N. Open-pit mining operational planning using multi agent systems. *Procedia Computer Science*. 2021; 192:1677–1686.
19. Hazrathosseini A., Afrapoli A.M. Intelligent fleet management systems in surface mining: status, threats, and opportunities. *Mining, Metallurgy & Exploration*. 2023.

© 2025 The Authors. This is an open access article under the CC BY license (<http://creativecommons.org/licenses/by/4.0/>).

The authors declare no conflict of interest.

About the authors:

Artem Yu. Voronov - Candidate of Technical Sciences, Associate Professor, Kemerovo, Russian Federation, T.F. Gorbachev Kuzbass State Technical University.

Ilya S. Syrkin - Candidate of Technical Sciences, Kemerovo, Russian Federation, T.F. Gorbachev Kuzbass State Technical University.

Dmitry A. Pashkov - Candidate of Technical Sciences, Kemerovo, Russian Federation, T.F. Gorbachev Kuzbass State Technical University; e-mail: pashkovda@kuzstu.ru

Contribution of the authors:

Artem Yu. Voronov – setting a research task, reviewing relevant literature, conceptualizing research, collecting and analyzing data, and writing a text.

Ilya S. Syrkin – setting a research task, reviewing relevant literature, collecting and analyzing data, and writing a text.

Dmitry A. Pashkov – scientific management, conceptualization of research, conclusions, writing the text..

All authors have read and approved the final manuscript.

