

Применение онтологического моделирования для автоматического отбора значимых признаков и семантической регуляризации моделей машинного обучения при разработке интеллектуальных информационных систем в электроэнергетике

П.В. Матренин

Уральский федеральный университет имени первого Президента России Б. Н. Ельцина, Екатеринбург

Аннотация: Онтологическое моделирование является перспективным направлением развития научно-методической базы разработки интеллектуальных информационных систем в электроэнергетике. В статье предложен новый подход к использованию онтологических моделей при создании систем искусственного интеллекта для прогнозирования временных рядов в задачах электроэнергетики. Введены формальные метрики: онтологическое расстояние между признаком и целевой переменной, а также семантическая релевантность признака. На примерах доменных онтологий для ветроэнергетики и электропотребления промышленного предприятия продемонстрированы алгоритмы расчета этих метрик и показано, как они позволяют проранжировать признаки, реализовать автоматизированный выбор наиболее значимых признаков, обеспечить семантическую регуляризацию обучения регрессионных моделей различных видов. Даны рекомендации по выбору коэффициентов для расчета метрик, проведен анализ теоретических свойств метрик и обозначены границы применимости предложенного подхода. Полученные результаты формируют основу для дальнейшей интеграции онтологической информации в математические и компьютерные модели прогнозирования генерации и потребления электроэнергии при разработке отраслевых интеллектуальных систем.

Ключевые слова: онтология, онтологическое расстояние, релевантность признаков, системный анализ, объяснимый искусственный интеллект, электроэнергетика, прогнозирование генерации, прогнозирование электропотребления.

Введение

Цифровизация электроэнергетики приводит к созданию все большего количества информационных систем, программных библиотек и продуктов, в связи с чем возникает научная проблема семантического согласования используемых в них моделей предметных областей и объектов данных. Онтологическое моделирование (ОМ) является одним из наиболее эффективных механизмов формализации знаний и создания общих математических и компьютерных моделей [1-3].

Онтология, согласно ГОСТ Р ИСО/МЭК 21838-1-2021 «Информационные технологии. Онтологии высшего уровня» – это совокупность терминов, выражений отношения и связанных с ними определений на естественном языке вместе с одной или несколькими формальными теориями, предназначенными для отражения заданных интерпретаций этих определений. Одна из центральных задач ОМ при разработке информационных систем – семантическая унификация. В электроэнергетике широко используется общая информационная модель (Common Information Model – CIM), изложенная в стандартах IEC 61968, 61970, 62325, и позволяющая унифицировать программные интерфейсы между информационными системами в электроэнергетике.

Существуют также онтологические модели, описанные в научных работах и открытых базах данных. Например, Open Energy Ontology (OEO) применяет формальный словарь для описания энергетических систем и унификации терминов [3]. Онтологии необходимы для создания цифровых двойников (ЦД) электроэнергетических систем и их элементов, что показано в работах [4–6]. Авторами статьи [4] обоснована необходимость построения онтологических моделей ЦД распределенной генерации с расширением CIM для интеграции в цифровые платформы управления. Исследования [5, 7] представляют фрагменты онтологических моделей в области возобновляемой энергетики и онтологии для создания ЦД фотоэлектрических систем. Обзор [8] описывает существующее программное обеспечение для создания ЦД в электроэнергетике и представляет специализированный язык для их описания, который является совместимым с онтологическими моделями.

Применение ОМ в области возобновляемых источников энергии (ВИЭ) представлено в ряде работ: [5, 7] для солнечных электрических станций и [9] для ветровых. Авторы [9] описывают ветроэнергетические установки,

включая в модель метеоусловия и нечеткие связи для мониторинга и прогнозирования выработки.

Другим направлением ОМ в электроэнергетике является их использование для создания мультиагентных систем (МАС) [10]. Обзор [11], посвященный применению ОМ в МАС энергосистемах, выделяет задачи, решаемые с помощью онтологий при описании агентов и их взаимодействий. ОМ может быть применено для перехода от математического описания МАС к разработке программного обеспечения, моделирующего процессы в такой системе [10, 12].

В таблице №1 приведены основные направления ОМ в электроэнергетике. В настоящее время онтологии в электроэнергетике используются как модели предметной области при создании интеллектуальных систем, основанных на явном представлении знаний.

Таблица № 1

Основные направления ОМ в электроэнергетике

Направление	Решаемые задачи	Примеры исследований
ЦД	Проектирование структуры, интеграция информационных систем и источников данных	Массель Л.В. и др. [1], Непша С.Ф. и др. [2]
Распределенные энергосистемы	Согласование СИМ-стандартов и специализированных моделей	Непша С.Ф. и др. [2, 4]
ВИЭ	Оценка состояния, мониторинг, прогнозирование	Массель Л.В. и др. [5], Kucuk D и др. [9]
МАС	Моделирование взаимодействия агентов	Хальясмаа А.И. и др. [10], Ma Z. и др. [11]

В задачах прогнозирования временных рядов в электроэнергетике в настоящее время наибольшую эффективность показывают интеллектуальные системы, основанные на машинном обучении из-за многофакторности, неопределенности и высокой сложности взаимовлияний природных, технологических и производственных процессов при генерации и потреблении электрической энергии [13, 14]. Анализ современного состояния исследований показывает, что онтологические модели остаются не интегрированными в процессы обработки и анализа данных на уровне алгоритмов машинного обучения.

В данной статье предлагается новый подход к интеграции ОМ и методов машинного обучения путем введения метрик онтологического расстояния и семантической релевантности признаков, а также онтологической регуляризации моделей машинного обучения. Рассматривается задача построения интеллектуальных систем прогнозирования генерации и потребления электрической энергии, основанного на онтологическом моделировании предметной области, который позволяет автоматически отбирать и интерпретировать признаки на основе их семантической релевантности, а также снижать переобучение моделей за счёт онтологической регуляризации, интегрированной в процедуру обучения прогнозных моделей.

Метод построения онтологически-релевантных прогнозных моделей

Предложенный метод включает в себя несколько этапов.

1. Формализация предметной области.
2. Вычисление онтологического расстояния и выбор релевантных признаков.
3. Использование онтологической модели для регуляризации при создании модели машинного обучения.

Онтологическая модель может быть представлена в виде кортежа

$$\mathcal{O} = \langle \mathcal{E}, \mathcal{R}, \mathcal{C}, \mathcal{L} \rangle,$$

где $\mathcal{E}$ — сущности, $\mathcal{R} \subset \mathcal{E} \times \mathcal{E}$ — отношения, $\mathcal{C}$ — иерархия классов, $\mathcal{L}$ — логические правила (в общем случае достаточно $\mathcal{O} = \langle \mathcal{E}, \mathcal{R} \rangle$, что образует онтологический граф).

Каждому признаку x_i сопоставляется сущность $o_i \in \mathcal{E}$. Если объект использует СИМ-модель или иную информационную модель, то вершины онтологии напрямую могут быть соотнесены с вершинами графа модели $\mathcal{G} = (V, E, A)$, что гарантирует семантическую совместимость и ускоряет интеграцию информационных систем.

Для целевой сущности $\mathcal{T} \subset \mathcal{E}$ вводится онтологическое расстояние и онтологическая значимость (семантическая релевантность) следующим образом:

$$d(o_i, \mathcal{T}) = \min(\text{длина пути между } o_i \text{ и } \mathcal{T}),$$

$$r_i = \exp(-\alpha d(o_i, \mathcal{T})), \quad r_i \in (0, 1].$$

Минимальное расстояние определяется с помощью алгоритма поиска в ширину (breadth-first search – BFS). Порог δ формирует множество релевантных признаков X_{rel} .

Пример показан на рис. 1.




Рисунок 1. Влияние онтологического расстояния на метрику релевантности признака

$$\Delta_j = RSS(S) - [RSS(S_L) + RSS(S_R)]R(r_j),$$

$$RSS(S) = \sum_{i \in S} (y_i - \bar{y}_S)^2,$$

$$\bar{y}_S = \frac{1}{n} \sum_{i \in S} y_i,$$

$$R(r_j) = \lg \left(r_j + \frac{1}{\mu_1 + \varepsilon} \right) / \lg \left(1 + \frac{1}{\mu_1 + \varepsilon} \right),$$

где Δ_j – прирост информации при расщеплении узла по j -му признаку; RSS – сумма квадратов отклонений прогнозных значений от истинных среди множества S объектов обучающей выборки, относящихся к узлу; n – мощность множества S ; S_L и S_R – подмножества S , образуемые при разбиении узла на две части (условно называемые левой и правой); R – функция для согласования статистической значимости признака на основе RSS и его семантической значимости r ; μ_1 – эвристический коэффициент учета онтологической регуляризации, ε – малое число (10^{-5}), необходимое, чтобы избежать ошибки при программной реализации расчета в случае равенства μ_1 нулю.

2. Для деревьев, полученных с помощью градиентного бустинга, прирост информации может быть рассчитан следующим образом.

Для каждого объекта i в узле известны градиент и гессиан функции ошибки L (как правило, среднеквадратичной ошибки модели):

$$g_i = \frac{\partial L(y, \hat{y})}{\partial \hat{y}}, \quad h_i = \frac{\partial^2 L(y, \hat{y})}{\partial \hat{y}^2},$$

Для любого подмножества S можно определить информативность:

$$G(S) = \sum_{i \in S} g_i, \quad H(S) = \sum_{i \in S} h_i.$$

$$Score(S) = -\frac{1}{2} \frac{G(S)^2}{H(S) + \lambda},$$

где $\lambda > 0$ – коэффициент L_2 регуляризации.

Прирост информации в этом случае определяется так:

$$\Delta_j = \frac{1}{2} \left[\frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + H_R + \lambda} \right] R(r_j),$$

$$G_L = G(S_L), G_R = G(S_R), H_L = H(S_L), H_R = H(S_R).$$

3. В случае более простых моделей, например, линейной или полиномиальной регрессии, задача оптимизации коэффициентов регрессии с учетом онтологической регуляризации записывается следующим образом:

$$L(W, b) = \frac{1}{2} \sum_{i=1}^N (y_i - (W^T x_i + b))^2 + \frac{\lambda}{2} |W|_2^2 + \mu_2 \cdot \sum_j (1 - r_j)^2 w_j^2$$

где W, b – коэффициенты регрессионной модели.

Пример использования онтологической дистанции

В качестве примера использована открытая онтология доменной модели ветроэнергетики [9], дополненная необходимыми сущностями и связями, так как в авторской модели приведены только структурные связи вида «has». В таблице №2 приведены ее характеристики.

Таблица № 2

Характеристики онтологической модели ветроэнергетики

Характеристика	Значение
Общее число классов	397
Число свойств объектов	67
Наибольший структурный кластер	Объекты с префиксом Wind, такие как скорость ветра (WindSpeed), направление ветра (WindDirection), ветротурбина (WindTurbine) и др.
Количество объектов, связанных с измерениями	11

На рисунке 2 показан фрагмент модели после добавления связей.




Рисунок 2. Фрагмент онтологической модели, используемый для выбора признаков

В таблице №3 приведены онтологические расстояния для основных сущностей, необходимых для прогноза выработки электроэнергии ветроэнергетической установкой.

Для задачи потребления электроэнергии промышленного предприятия выполнен анализ электропотребления угольного разреза согласно описаниям [15, 16]. Особенность заключается в том, что помимо производственного плана добычи высокое влияние оказывают геологические факторы (характеристики горной породы) и метеорологические. Масса горной породы, а следовательно, и электропотребление ковшей экскаваторов, зависят от температуры воздуха, а электропотребление водоткачивающих насосов от температуры и осадков. Кроме того, влияют характеристики карьерных экскаваторов, такие как удельное электропотребление.

В таблице №4 приведены результаты расчетов онтологической дистанции для измеряемых параметров.

Таблица №3

Онтологические метрики расстояния и значимости при прогнозировании
генерации ветроэнергетической установки

Сущность	Измеряемая величина (Да/Нет)	Количество переходов по графу до целевой переменной	Онтологическое расстояние при $\alpha = 0,1$	Онтологическое расстояние при $\alpha = 0,7$
Электроэнергия	Да	0	1	1
Мощность ветропотока	Нет	1	0,90	0,50
Плотность воздуха	Нет	2	0,82	0,25
КПД турбины	Нет	1	0,90	0,50
Скорость ветра (горизонтальная)	Да	2	0,82	0,25
Атмосферное давление	Да	3	0,74	0,12
Влажность воздуха	Да	3	0,74	0,12
Скорость ветра (вертикальная)	Да	2	0,82	0,25
Направление ветра	Да	2	0,82	0,25
Температура воздуха	Да	2	0,82	0,25

Результаты согласуются с описанными в работе [16] особенностями задачи, в частности, что основным признаком для прогнозирования электропотребления угольного разреза является график потребления за несколько предыдущих суток и календарные признаки, в то время как планы, геологические и метеорологические факторы несмотря на существенное

влияние на электропотребление, слабо влияют на точность прогноза из-за высокой сложности их учета и существенной неопределенности технологических процессов.

Таблица №4

Онтологические метрики расстояния и значимости при прогнозировании
электропотребления угольного разреза

Сущность	Количество переходов	Онтологическое расстояние при $\alpha = 0,7$
Электроэнергия	0	1
Плановый объем поднятой горной породы	4	0,06
Плановое количество пробуренных скважин	4	0,06
Плановая глубина пробуренных скважин	4	0,06
Удельная энергоемкость экскаваторов	3	0,12
Удельная энергоемкость буровых установок	3	0,12
Удельная энергоемкость водоотливных насосов	3	0,12
Температура воздуха	4	0,06
Количество осадков	4	0,06
Час суток	2	0,25
Рабочий день	2	0,25

Теоретический анализ метрик

Можно сформулировать ряд свойств предложенных метрик.

1. Монотония. Добавление прямого отношения между двумя сущностями либо уменьшает, либо оставляет неизменным значения метрик. Это гарантирует, что уточнение онтологии за счёт новых связей не приведёт к снижению значимости признака.

2. Невырожденность. Для $o_i = \mathcal{T}$ выполняется $d = 0$; а при отсутствии пути – $d = \infty$. Тем самым метрика корректно отражает как полную семантическую тождественность, так и несвязность.

3. Симметрия. В ориентированном графе $d(o_i, \mathcal{T}) = d(\mathcal{T}, o_i)$ в общем случае; это соответствует свойству инверсии связей в онтологической модели.

4. Вычислительная сложность линейна – $O(|E|)$.

5. Треугольное неравенство. Для неориентированного представления онтологии свойство выполняется, обеспечивая метрическое пространство.

$$d(a, c) \leq d(a, b) + d(b, c) \text{ для любых трёх точек } a, b, c.$$

Метрика с треугольным неравенством может быть использована для алгоритмов кластеризации и многомерного шкалирования

Пороговое множество релевантных признаков $X_{rel} = \{x_i \mid d(o_i, \mathcal{T}) < \delta\}$ регулирует баланс между полнотой и точностью. При $\delta = 2$ в типичных онтологиях глубиной 4–5 сохраняются только непосредственные и ближайшие косвенные связи, что подтверждается приведенными примерами.

Параметр α управляет скоростью экспоненциального затухания релевантности. Значения $\alpha > 1$ «обнуляют» вклад всех признаков с $d \geq 3$, при $\alpha < 0,3$ различия между близкими и дальними сущностями сглаживаются. Практически оправдан интервал $0,5 \leq \alpha \leq 0,8$, при котором сохраняется градуированное влияние признаков.

Помимо уже отмеченных задач выбора признаков и регуляризации моделей предложенные метрики могут использоваться для повышения объяснимости моделей машинного обучения. Например, возможно формировать пояснения вида «Влажность воздуха оказала влияние на прогноз, поскольку связана с выработкой электроэнергии через цепочку плотность воздуха – мощность ветропотока – ветротурбина». Такой вывод понятен инженеру-энергетику и усиливает доверие пользователей к системе.

К ограничениям подхода относятся:

- ошибки выбора признаков при отсутствии в онтологии необходимых связей, поэтому после выбора признаков рекомендуется выполнить экспертную верификацию;

- изменение предметной области требует пересчета метрик, поэтому для моделей машинного обучения необходимо указывать версию используемой онтологической модели.

Заключение

Рассмотрена задача разработки доверенных интеллектуальных систем прогнозирования в электроэнергетике, в которых семантические знания предметной области качественно и количественно интегрируются в алгоритмы машинного обучения.

Введены количественные метрики онтологического расстояния и релевантности, удовлетворяющие основным требованиям для применения при разработке моделей машинного обучения и опирающиеся исключительно на топологию онтологической модели. Вычисление метрик показано на примерах задач прогнозирования генерации ветроэнергетической установки и электрической нагрузки промышленного предприятия. Обоснована возможность использования предложенного подхода для автоматического выбора признаков и мягкой регуляризации параметров моделей машинного обучения. Обозначены риски, связанные с неполнотой и изменчивостью онтологических моделей, а также предложены способы их минимизации.

В дальнейшем планируется выполнить исследование расширения метрик для применения к графам, содержащим взвешенные и нечеткие ребра (например, «измеряет» важнее при выборе признаков, чем «расположен_на», что переводит метрику от счетной длины пути к стоимости пути и учитывает семантическую силу связей); а также выполнить анализ влияния онтологической регуляризации на качество обучения прогнозных моделей по критериям средней погрешности и устойчивости к переобучению.

Литература

1. Массель Л.В., Массель А.Г. Построение экосистемы знаний на основе ИТ-инфраструктуры системных исследований в энергетике // Вестник Югорского государственного университета. 2023. Т. 19. №4. С. 78-87.
2. Nepsha S.F., Nebera A.A., Andrievsky A.A., Krasilnikov M.I. Development of an Ontology for Smart Distributed Energy Systems * // IFAC-PapersOnLine. 2022. Vol. 55 (9). pp. 454-459.
3. Booshehri M. et al. Introducing the Open Energy Ontology: Enhancing data interpretation and interfacing in energy systems analysis // Energy and AI. 2021. Vol. 5. P. 100074.
4. Андриевский А.А., Красильников М.И., Непша Ф.С. Онтология как основа для создания цифровых двойников объектов управления интеллектуальной распределённой энергетики // Автоматизация в промышленности. 2021. № 1. URL: avtprom.ru/article/ontologiya-kak-osnovadlya-sozda.
5. Массель Л.В., Массель А.Г., Щукин Н.И., Цыбиков А.Р., Лосев А.С. Построение цифровых двойников ветровой и солнечной электростанций на основе онтологического подхода // Автоматизация в промышленности. 2022. №7. URL: avtprom.ru/article/postroenie-tsifrovyykh-dvoynikov.
6. Luo F., Feng S., Yang Y., A. Zhiqi, Li X., Chai Y. Ontology modeling for time-series simulation of distribution networks // Frontiers in Energy Research. 2022. Vol 10. URL: frontiersin.org/journals/energy-research/articles/10.3389/fenrg.2022.935026/full.
7. Массель Л.В., Массель А.Г. Семантическое моделирование при построении цифровых двойников энергетических объектов и систем // Онтология проектирования. 2023. Т. 13. №1. С. 44-54.

8. Iumanova I.F., Matrenin P.V., Khalyasmaa A.I. Review of Existing Tools for Software Implementation of Digital Twins in the Power Industry // Inventions. 2024. Vol. 9 (5). P. 101. URL: mdpi.com/2411-5134/9/5/101

9. Kucuk D., Kucuk D. OntoWind: An Improved and Extended Wind Energy Ontology // ArXiv. 2018. URL: arxiv.org/abs/1803.02808.

10. Хальясмаа А.И., Ерошенко С.А., Юманова И.Ф., Степанова А.И., Матренин П.В. Интеллектуальные мультиагентные системы в электроэнергетике // Новосибирск: Новосибирский государственный технический университет. 2023. 222 с.

11. Ma Z., Schultz M.J., Christensen K., Værbak M., Demazeau Y., Jorgensen B.N. The Application of Ontologies in Multi-Agent Systems in the Energy Sector: A Scoping Review // Energies. 2019. Vol. 12. P. 3200. URL: mdpi.com/1996-1073/12/16/3200.

12. Аксенов К.А., Неволина А.Л., Аксенова О.П., Камельский В.Д. Разработка модели логистики на основе интеграции концептуального, объектно-ориентированного, мультиагентного и имитационного моделирования, интеллектуальных систем // Инженерный вестник Дона. 2013. №1. URL: ivdon.ru/magazine/archive/n1y2013/1486.

13. Ahmad N., Ghadi Y., Adnan M., Ali M. Load Forecasting Techniques for Power System: Research Challenges and Survey // IEEE Access. 2022. Vol. 10. pp. 71054-71090.

14. Матренин П.В., Манусов В.З., Сафаралиев М.Х., Назаров М.Х. Модели и методы машинного обучения в задачах прогнозирования генерации на основе возобновляемых источников энергии // Новосибирск: Новосибирский государственный технический университет. 2024. 199 с.

15. Соловьёв Д.Б. Анализ электропотребления угольного разреза при внедрении автоматизированной системы учета электрической энергии // Горное оборудование и электромеханика. 2021. № 10. С. 17-20.

16. Matrenin P.V., Manusov V.Z., Khalyasmaa A.I., Antonenkov D.V., Eroshenko S.A., Butusov D.N. Improving accuracy and generalization performance of small-size recurrent neural networks applied to short-term load forecasting // Mathematics. 2020. Vol. 8 (12). P. 2169. URL: mdpi.com/2227-7390/8/12/2169.

References

1. Massel L.V., Massel A.G. Vestnik Yugorskogo gosudarstvennogo universiteta. 2023. Vol. 19. №4. pp. 78-87.

2. Nepsha S.F., Nebera A.A., Andrievsky A.A., Krasilnikov M.I. Development of an Ontology for Smart Distributed Energy Systems *. IFAC-PapersOnLine. 2022. Vol. 55 (9). pp. 454-459.

3. Booshehri M. et al. Introducing the Open Energy Ontology: Enhancing data interpretation and interfacing in energy systems analysis. Energy and AI. 2021. Vol. 5. P. 100074.

4. Andrievskij A.A., Krasilnikov M.I., Nepsha F.S. Avtomatizaciya v promy`shlennosti. 2021. № 1. URL: avtprom.ru/article/ontologiya-kak-osnovadlya-sozda.

5. Massel L.V., Massel A.G., Shhukin N.I., Cybikov A.R., Losev A.S. Avtomatizaciya v promy`shlennosti. 2022. №7. URL: avtprom.ru/article/postroenie-tsifrovyykh-dvoinikov.

6. Luo F., Feng S., Yang Y., A. Zhiqi, Li X., Chai Y. Ontology modeling for time-series simulation of distribution networks. Frontiers in Energy Research. 2022. Vol 10. URL: frontiersin.org/journals/energy-research/articles/10.3389/fenrg.2022.935026/full.

7. Massel L.V., Massel A.G. Ontologiya proektirovaniya. 2023. Vol. 13. №1. pp. 44-54.

8. Iumanova I.F., Matrenin P.V., Khalyasmaa A.I. Review of Existing Tools for Software Implementation of Digital Twins in the Power Industry. Inventions. 2024. Vol. 9 (5). P. 101. URL: mdpi.com/2411-5134/9/5/101

9. Kucuk D., Kucuk D. OntoWind: An Improved and Extended Wind Energy Ontology. ArXiv. 2018. URL: arxiv.org/abs/1803.02808.

10.10. Xalyasmaa A.I., Eroshenko S.A., Yumanova I.F., Stepanova A.I., Matrenin P.V. Intellektual'ny'e mul'tiagentny'e sistemy` v e'lektroe`nergetike [Intellectual multiagent systems in the power industry] Novosibirsk: Novosibirskij gosudarstvenny`j texnicheskij universitet [Novosibirsk State Technical University]. 2023. 222 p.

11.Ma Z., Schultz M.J., Christensen K., Værbak M., Demazeau Y., Jorgensen B.N. The Application of Ontologies in Multi-Agent Systems in the Energy Sector: A Scoping Review. Energies. 2019. Vol. 12. P. 3200. URL: mdpi.com/1996-1073/12/16/3200.

12.Aksenov K.A., Nevolina A.L., Aksenova O.P., Kamelskij V.D. Inzhenernyj vestnik Dona. 2013. № 1. URL: ivdon.ru/magazine/archive/n1y2013/1486.

13.Ahmad N., Ghadi Y., Adnan M., Ali M. Load Forecasting Techniques for Power System: Research Challenges and Survey. IEEE Access. 2022. Vol. 10. pp. 71054-71090.

14.Matrenin P.V., Manusov V.Z., Safaraliev M.X., Nazarov M.X. Modeli i metody` mashinnogo obucheniya v zadachax prognozirovaniya generacii na osnove vozobnovlyaemy`x istochnikov e`nergii [Machine learning models and methods for problems of renewable energy sources generation forecasting]. Novosibirsk: Novosibirskij gosudarstvenny`j texnicheskij universitet. 2024. 199 p.

15.Solovyov D.B. Gornoe oborudovanie i e'lektromexanika. 2021. № 10. pp. 17-20.

16.Matrenin P.V., Manusov V.Z., Khalyasmaa A.I., Antonenkov D.V., Eroshenko S.A., Butusov D.N. Mathematics. 2020. Vol. 8 (12). P. 2169. URL: mdpi.com/2227-7390/8/12/2169.

Дата поступления: 9.07.2025

Дата публикации: 25.08.2025