

ПРОГНОЗИРОВАНИЕ ЭНЕРГОЗАТРАТ В СИСТЕМАХ УПРАВЛЕНИЯ ДОМАШНИМ ЭНЕРГОПОТРЕБЛЕНИЕМ С ПРИМЕНЕНИЕМ МЕТОДА МАШИННОГО ОБУЧЕНИЯ

УДК 681.5

Коротеев Дмитрий Дмитриевич

канд. техн. наук, доцент, Московский государственный строительный университет (кафедра технологий и организации строительного производства), г. Москва, Россия; KoroteevMGSU@yandex.ru

Коротеева Татьяна Александровна

ведущий инженер, ФГУП «Центральные научно-реставрационные проектные мастерские», г. Москва, Россия; Zakaruchka@inbox.ru

Хуан Цзюежу

аспирант, Российский университет дружбы народов (Департамент строительства), г. Москва, Россия; huangjueru52@qq.com

Статья получена: 02.04.2023. Одобрена: 18.05.2023. Опубликовано онлайн: 27.06.2023 © РИОР

Аннотация. Сокращение энергопотребления объектами капитального строительства на всех стадиях их жизненного цикла является актуальной задачей для строительной отрасли и жилищно-коммунального комплекса. В статье рассматриваются пути сокращения энергозатрат при эксплуатации жилых зданий. Целью исследования является разработка методики прогнозирования энергозатрат при использовании системы управления домашнего энергопотребления на основе метода машинного обучения. Все устройства, входящие в систему «умного дома» разделены на три типа, для каждого из них описана методика расчёта энергопотребления. Ал-

горитм работы системы управления домашним энергопотреблением заключается в получении от поставщика энергоресурсов информации об их стоимости на час вперед, расчете энергозатрат всех устройств и прогнозировании энергопотребления на основе метода машинного обучения с подкреплением. Эффективность выбранного метода и достоверность прогнозирования оценивалась путем сопоставления результатов с реальными затратами за выбранный временной период, а также вычисления средней абсолютной ошибки и средней абсолютной ошибки в процентах. Результаты исследования свидетельствуют об перспективности применения метода машин-

FORECASTING ENERGY CONSUMPTION IN HOME ENERGY MANAGEMENT SYSTEMS USING MACHINE LEARNING METHOD

Koroteev Dmitry

PhD in Engineering, Associate Professor, Moscow State University of Civil Engineering (Kafedra tehnologii i organizacii stroitel'nogo proizvodstva), Moscow, Russian Federation; KoroteevMGSU@yandex.ru

Koroteeva Tatiana

Leading Engineer, Federal State Unitary Enterprise «Central Scientific and Restoration Design Workshops», Moscow, Russian Federation; Zakaruchka@inbox.ru

Huang Jueru

graduate student, Peoples' Friendship University of Russia (Department of Civil Engineering), Moscow, Russian Federation; huangjueru52@qq.com

Abstract: Reducing energy consumption by capital construction projects at all stages of their life cycle is an urgent task for the construction industry and the housing and communal complex. The

article discusses ways to reduce energy costs in the operation of residential buildings. The aim of the study is to develop a methodology for predicting energy costs when using a home energy management system based on the machine learning method. All devices included in the «smart home» system are divided into three types, for each of them a method for calculating energy consumption is described. The algorithm of the home energy management system is to receive information from the energy supplier about their cost an hour in advance, calculate the energy consumption of all devices and predict energy consumption based on the reinforcement machine learning method. The effectiveness of the chosen method and the reliability of forecasting were evaluated by comparing the results with real costs for the selected time and calculating the average absolute error and the average absolute error in percent. The results of the study indicate the promise of using the method of machine learning with reinforcement to build a home energy management system based on forecasting energy consumption over time.

Keywords: home energy management system, reinforcement learning method, energy saving in construction, life cycle of capital construction projects

ного обучения с подкреплением для выстраивания системы управления домашним энергопотреблением на основе прогнозирования энергозатрат во времени.

Ключевые слова: система управления домашним энергопотреблением, метод машинного обучения с подкреплением, энергосбережение в строительстве, жизненный цикл объектов капитального строительства

Введение

Снижение энергетических затрат объектами капитального строительства является актуальным на всех стадиях их жизненного цикла, особенно на наиболее продолжительной стадии — эксплуатации здания. Это связано с тем, что строительная отрасль и жилищно-коммунальный комплекс являются одними из крупнейших потребителей энергетических ресурсов и испытывают повышенный спрос на энергию, который приводит к увеличению расходов на развитие и укрепление энергетической инфраструктуры [1, 2].

Снижение энергозатрат объектами капитального строительства возможно за счет выстраивания системы разумного энергопотребления и применения альтернативных источников энергии как на эксплуатационной, так и на других стадиях их жизненного цикла [3, 4].

В последние годы в странах с развитой экономикой происходит сокращение государственного регулирования оптового рынка энергии и открытие новых возможностей для автономных производителей и поставщиков энергии, что приводит к изменению способов продажи и покупки энергетических ресурсов [5]. Устойчивый тренд на снижение энергопотребления в строительном секторе наблюдается и в нашей стране, что подтверждается принятым в 2009 году Федеральным Законом РФ №261-ФЗ «Об энергосбережении и о повышении энергетической эффективности, и о внесении изменений в отдельные законодательные акты Российской Федерации», изданным в 2011 году Приказом Министерства регионального развития РФ №161 «Об утверждении Правил определения классов энергетической эффективности многоквартирных домов и Требований к указателю класса энергетической эффективности многоквартирного дома, размещаемого на фасаде многоквартирного дома», а также рядом других документов [6].

Для выстраивания системы разумного энергопотребления операторы энергетической инфраструктуры, прежде всего электросетей, внедряют гибкое тарифное планирование и программы регулирования

спроса на энергию, сокращающие энергозатраты в определённые промежутки времени и выстраивающие баланс между спросом и предложением [7].

Гибкое тарифное планирование позволяет менять тарифы на электроэнергию в зависимости от времени суток, дня недели и месяца. В него входят пиковые, средние и непииковые периоды. Подобный подход предоставляет потребителю возможность сместить потребление электроэнергии на более дешёвые периоды, тем самым контролируя свое энергопотребление [8]. Несмотря на то, что гибкое тарифное планирование снижает пиковое потребление энергии, оно может привести к такому же или даже большему энергопотреблению в непииковые часы.

Программы регулирования спроса могут быть оощрительными, предоставляющими потребителям льготные условия использования энергии при уровне потребления меньше установленного порога, и принудительными, предусматривающими как значительное увеличение цен на энергию при превышении лимита, так и принудительное ограничение доступа к энергоресурсам [9, 10]. Программное обеспечение, реализующее подобные алгоритмы, может быть использовано коммунальными службами, управляющими компаниями и т.п.

В последнее время начали появляться системы управления домашним энергопотреблением, позволяющие выстроить максимально гибкий баланс спроса и предложения для каждого отдельного потребителя. Они объединяются в общую систему «умного дома» и позволяют учитывать энергопотребление каждого потребителя в общей программе регулирования спроса многоквартирных домов [11-13].

Целью исследования является разработка методики прогнозирования энергозатрат в системах управления домашним энергопотреблением с применением методов машинного обучения.

Объектом исследования являются системы управления домашним энергопотреблением. Предметом исследования является применение методов машинного обучения в работе систем управления домашним энергопотреблением.

Методология

Для прогнозирования энергозатрат в системах управления домашним энергопотреблением был выбран метод машинного обучения с подкреплением, предполагающий обучение на своем опыте и адаптацию для достижения наилучших результатов [14]. Планирование энергопотребления выполняется с

использованием многоагентного обучения, при этом каждое домашнее устройство представляет собой среду, содержащую своего собственного агента с различными мерами и вознаграждениями [15, 16].

Выбранный алгоритм работы системы управления домашним энергопотреблением позволяет пользователю получить данные о стоимости энергии на 1 час вперед и прогнозировать предстоящие энергозатраты [17]. Вместе с прогнозированием предстоящих затрат метод машинного обучения с подкреплением используется для принятия оптимального решения для различных устройств с использованием децентрализованного подхода, при этом вычислительная нагрузка переносится с центрального оптимизатора на группу интеллектуальных агентов [18].

Система управления получает данные о стоимости энергии на час вперед от поставщиков энергоресурсов, при этом энергопотребление каждого n -го устройства в момент времени t можно описать уравнением (1).

$$E_{n,t} = e_{n,t} \quad (1)$$

где $n \in \{1, \dots, N\}$ — номер устройства от 1 до N ;
 $t \in \{1, \dots, T\}$ — момент времени (час в сутках от 1 до $T = 24$); $e_{n,t}$ — потребность в энергии n -го устройства в момент времени t .

Домашние устройства по своим техническим характеристикам и возможностям разделены на 3 группы:

1. С непереключаемой нагрузкой;
2. С переключаемой нагрузкой;
3. С регулируемой нагрузкой (освещение, кондиционирование).

Для устройств с непереключаемой нагрузкой стоимость энергопотребления определяется уравнением (2).

$$C_{n,t}^H = c_t E_{n,t}^H \quad (2)$$

где c_t — стоимость энергии в момент времени t , $E_{n,t}^H$ — потребление энергии n -го устройства с нерегулируемой нагрузкой в момент времени t .

Для устройств с переключаемой нагрузкой есть 2 положения: включено и выключено, энергопотребление при этом можно описать уравнением (3).

$$E_{n,t}^П = I_{n,t} e_{n,t}^П \quad (3)$$

где $I_{n,t}$ — текущее положение n -го устройства, $I_{n,t} = 1$ когда устройство в положении «включено», $I_{n,t} = 0$ когда устройство в положении «выключено».

Для устройств с переключаемой нагрузкой существует 2 типа стоимостных затрат: за потребление

энергии и дискомфорт, связанный с ожиданием запуска и завершения работы устройства (4-6).

$$C_{n,t}^П = c_t E_{n,t}^П + k_n (T_{n,н.р} - T_{n,нач}) \quad (4)$$

$$T_{n,нач} \leq T_{n,н.р} \leq [T_{n,кон} - T_{n,раб}] \quad (5)$$

$$T_{n,раб} \leq T_{n,кон} - T_{n,нач} \quad (6)$$

где k_n — коэффициент, учитывающий переключение режима работы;

$T_{n,нач}$ — время начала эксплуатации устройства;
 $T_{n,кон}$ — время окончания эксплуатации устройства;
 $T_{n,н.р}$ — время начала работы устройства;
 $T_{n,раб}$ — время, необходимое для выполнения устройством своей работы.

Устройства с регулируемой нагрузкой могут переходить из режима с наименьшим ($e_{n,min}$) к режиму с наибольшим ($e_{n,max}$) энергопотреблением по мере изменения цен, стоимость в данном случае можно определить по формулам (7-9).

$$E_{n,t}^P = e_{n,t}^P \quad (7)$$

$$e_{n,min} \leq e_{n,t}^P \leq e_{n,max} \quad (8)$$

$$C_{n,t}^P = c_t E_{n,t}^P + \beta_n (E_{n,t}^P - e_{n,max})^2 \quad (9)$$

Целью приборов этой группы является снижение энергозатрат пользователя, которое, однако, может привести к его дискомфорту при понижении режима работы устройства, что отражается переменной β_n .

Минимальные затраты на энергию и дискомфорт, связанные с изменением режима работы домашних устройств определяется по формуле (10).

$$\min \sum_{n=1}^N \sum_{t=1}^T \left\{ \begin{aligned} &(1-\rho) P_t (E_{n,t}^H + E_{n,t}^П + E_{n,t}^P) \\ &+ \rho \left[\begin{aligned} &k_n (T_{n,н.р} - T_{n,нач}) \\ &+ \beta_n (E_{n,t}^P - e_{n,max})^2 \end{aligned} \right] \end{aligned} \right\} \quad (10)$$

где ρ — переменная компромисса для достижения баланса между ценами на энергию и дискомфортом в соответствии с предпочтениями потребителя.

Эффективность метода оценивалась через среднюю абсолютную ошибку (MAE) и среднюю абсолютную ошибку в процентах (MAPE) между прогнозируемыми и реальными затратами на энергию в соответствии с уравнением (11) и (12).

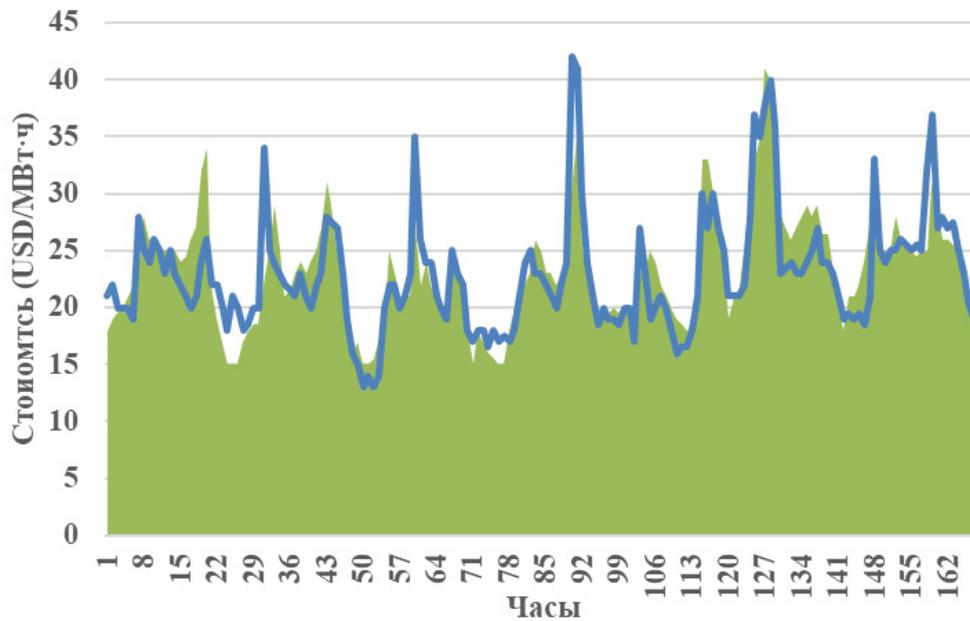


График реальных и прогнозируемых затрат в период с 22 по 28 февраля 2022 г.

$$MAE = \frac{1}{T} \sum_{t=1}^T |C_t - C_t^f| \quad (11)$$

$$MAPE = \frac{100}{T} \sum_{t=1}^T \frac{|C_t - C_t^f|}{C_t} \quad (12)$$

где C_t — реальная стоимость энергии;
 C_t^f — прогнозируемая стоимость энергии.

Результаты

Алгоритм работы системы запускается в начале дня, то есть в момент времени $t = 1$, при этом инициализируется номинальная мощность, время работы, переменная цены дискомфорта и переменная компромисса. Используя переменные, в каждый час t система обновляет входные данные использует метод машинного обучения с подкреплением для прогнозирования предстоящих затрат на следующий час. Затем система вычисляет оптимальное решение для всех устройств, используя прогнозируемые предстоящие затраты.

Метод машинного обучение с подкреплением протестирован с использованием информации о стоимости и мощности рынка электроэнергии, полученной из открытых источников с помощью расширения Data Miner. Информация для обучения была взята в период с 1 января 2022 г. по 21 февраля 2022 г., а затем

выполнено прогнозирование затрат в период с 22 по 28 февраля 2022 г. Архитектура используемой нейронной сети содержит 5 слоев: 1 входной слой с 18 нейронами, 3 скрытых слоя с 40, 20 и 10 нейронами и 1 выходной слой с 1 нейроном.

График иллюстрирует разницу между прогнозируемыми (зеленый цвет) и реальными (синий цвет) затратами за выбранный период времени.

Согласно графику, прогнозируемые затраты следуют той же тенденции, что и реальные затраты, при этом MAE составляет 2,12, а MAPE составляет 8,59%.

Заключение

Результаты сравнения прогнозируемых и реальных затрат, а также вычисленные средняя абсолютная ошибка и средняя абсолютная ошибка в процентах, не превышающая 10%, подтверждают применимость разработанной методики прогнозирования энергозатрат в системах управления домашним энергопотреблением с применением методов машинного обучения. Результаты исследования также свидетельствуют об перспективности применения метода машинного обучения с подкреплением для выстраивания системы управления домашним энергопотреблением на основе прогнозирования энергозатрат во времени.

Список литературы

- Hong, J. A Framework for Reducing Dust Emissions and Energy Consumption on Construction Sites / J. Hong, T. Hong, H. Kang, M. Lee // *Energy Procedia*. — 2019. — Vol. 158. — P. 5092-5096. — doi.org/10.1016/j.egypro.2019.01.637.
- Huang, J. Artificial intelligence for planning of energy and waste management / J. Huang, D. D. Koroteev // *Sustainable energy technologies and assessments*. — 2021. — Vol. 47. — P. 101426. — DOI 10.1016/j.seta.2021.101426.
- Tadeu, S. Eco-efficiency to support selection of energy conservation measures for buildings: A life-cycle approach / S. Tadeu, C. Rodrigues, P. Marques, F. Freire // *Journal of Building Engineering*. — 2022. — Vol. 61. — P. 105142. — doi.org/10.1016/j.jobe.2022.105142.
- Shahrabi, E. Developing optimal energy management of energy hub in the presence of stochastic renewable energy resources / E. Shahrabi, S.M. Hakimi, A. Hasankhani, G. Derakhshan, B. Abdi // *Sustainable Energy, Grids and Networks*. — 2021. — Vol. 26. — P. 100428. — doi.org/10.1016/j.segan.2020.100428.
- Yan, X. A review on price-driven residential demand response / X. Yan, Y. Ozturk, Z. Hu, Y. Song // *Renewable and Sustainable Energy Reviews*. — 2018. — Vol. 96. — P. 411-419. — doi.org/10.1016/j.rser.2018.08.003.
- Коротеев, Д. Д. Законодательство в сфере энергосбережения в строительстве / Д. Д. Коротеев // *Современные проблемы механики, энергоэффективность сооружений и ресурсосберегающие технологии: Сборник трудов научной школы-семинара молодых ученых и студентов с международным участием, Москва, 15–17 сентября 2015 года. — Москва: Российский университет дружбы народов, 2015. — С. 243-245.*
- Nguyen, H. Optimal demand side management scheduling-based bidirectional regulation of energy distribution network for multi-residential demand response with self-produced renewable energy / H. Nguyen, U. Safder, J. Loy-Benitez, C. Yoo // *Applied Energy*. — 2022. — Vol. 322. — P. 119425. — doi.org/10.1016/j.apenergy.2022.119425.
- Chen, Z. Multi-objective residential load scheduling approach for demand response in smart grid / Z. Chen, Y. Chen, R. He, J. Liu, M. Gao, L. Zhang // *Sustainable Cities and Society*. — 2022. — Vol. 76. — P. 103530. — doi.org/10.1016/j.scs.2021.103530.
- Li, S. Double-layer energy management system based on energy sharing cloud for virtual residential microgrid / S. Li, J. Zhu, Z. Chen, T. Luo // *Applied Energy*. — 2021. — Vol. 282. — P. 116089. — doi.org/10.1016/j.apenergy.2020.116089.
- Jasim, A.M. A new optimized demand management system for smart grid-based residential buildings adopting renewable and storage energies / A.M. Jasim, B.H. Jasim, A. Flah, V. Bolshev, L. Mihet-Popa // *Energy Reports*. — 2023. — Vol. 9. — P. 4018-4035. — doi.org/10.1016/j.egy.2023.03.038.
- Duman, A. C. A home energy management system with an integrated smart thermostat for demand response in smart grids / A. C. Duman, A. C. Erden, . G n l, . G ler // *Sustainable Cities and Society*. — 2021. — Vol. 65. — P. 102639. — doi.org/10.1016/j.scs.2020.102639.
- Aliero, M.S. Smart Home Energy Management Systems in Internet of Things networks for green cities demands and services / M.S. Aliero, K.N. Qureshi, M.F. Pasha, G. Jeon // *Environmental Technology & Innovation*. — 2021. — Vol. 22. — P. 101443. — doi.org/10.1016/j.eti.2021.101443.
- Gon alves, I. Optimizing the management of smart home energy resources under different power cost scenarios / I. Gon alves, . Gomes, C.H. Antunes // *Applied Energy*. — 2019. — Vol. 242. — P. 351-363. — doi.org/10.1016/j.apenergy.2019.03.108.
- Сорокин, И. В. Анализ опыта применения методов машинного обучения в строительной отрасли России / И. В. Сорокин, А. В. Настычук // *Строительство и архитектура*. — 2023. — Т. 11, № 1. — С. 18. — DOI 10.29039/2308-0191-2022-11-1-18-18.
- Park, K. Multi-agent deep reinforcement learning approach for EV charging scheduling in a smart grid / K. Park, I. Moon // *Applied Energy*. — 2022. — Vol 328. — P. 120111. — doi.org/10.1016/j.apenergy.2022.120111.
- Wang, Y. Cooperative energy management and eco-driving of plug-in hybrid electric vehicle via multi-agent reinforcement learning / Y. Wang, Y. Wu, Y. Tang, Q. Li, H. He // *Applied Energy*. — 2023. — Vol. 332. — P. 120563. — doi.org/10.1016/j.apenergy.2022.120563.
- Lehna, M. Forecasting day-ahead electricity prices: A comparison of time series and neural network models taking external regressors into account / M. Lehna, F. Scheller, H. Herwartz // *Energy Economics*. — 2022. — Vol. 106. — P. 105742. — doi.org/10.1016/j.eneco.2021.105742.
- Keles, D. Extended forecast methods for day-ahead electricity spot prices applying artificial neural networks / D. Keles, J. Scelle, F. Paraschiv, W. Fichtner // *Applied Energy*. — 2016. — Vol. 162. — P.218-230. — doi.org/10.1016/j.apenergy.2015.09.087.

References

- Hong, J. A Framework for Reducing Dust Emissions and Energy Consumption on Construction Sites / J. Hong, T. Hong, H. Kang, M. Lee // *Energy Procedia*. — 2019. — Vol. 158. — P. 5092-5096. — doi.org/10.1016/j.egypro.2019.01.637.
- Huang, J. Artificial intelligence for planning of energy and waste management / J. Huang, D. D. Koroteev // *Sustainable energy technologies and assessments*. — 2021. — Vol. 47. — P. 101426. — DOI 10.1016/j.seta.2021.101426.
- Tadeu, S. Eco-efficiency to support selection of energy conservation measures for buildings: A life-cycle approach / S. Tadeu, C. Rodrigues, P. Marques, F. Freire // *Journal of Building Engineering*. — 2022. — Vol. 61. — P. 105142. — doi.org/10.1016/j.jobe.2022.105142.
- Shahrabi, E. Developing optimal energy management of energy hub in the presence of stochastic renewable energy resources / E. Shahrabi, S.M. Hakimi, A. Hasankhani, G. Derakhshan, B. Abdi // *Sustainable Energy, Grids and Networks*. — 2021. — Vol. 26. — P. 100428. — doi.org/10.1016/j.segan.2020.100428.
- Yan, X. A review on price-driven residential demand response / X. Yan, Y. Ozturk, Z. Hu, Y. Song // *Renewable and Sustainable Energy Reviews*. — 2018. — Vol. 96. — P. 411-419. — doi.org/10.1016/j.rser.2018.08.003.
- Koroteev, D.D. Legislation in the field of energy saving in construction / D.D. Koroteev // *Modern problems of mechanics, energy efficiency of buildings and resource-saving technologies: Proceedings of the scientific school-seminar of*

- young scientists and students with international participation, Moscow, September 15–17, 2015. — Moscow: Peoples' Friendship University of Russia, 2015. — P. 243-245.
7. Nguyen, H. Optimal demand side management scheduling-based bidirectional regulation of energy distribution network for multi-residential demand response with self-produced renewable energy / H. Nguyen, U. Safder, J. Loy-Benitez, C. Yoo // *Applied Energy*. — 2022. — Vol. 322. — P. 119425. — doi.org/10.1016/j.apenergy.2022.119425.
 8. Chen, Z. Multi-objective residential load scheduling approach for demand response in smart grid / Z. Chen, Y. Chen, R. He, J. Liu, M. Gao, L. Zhang // *Sustainable Cities and Society*. — 2022. — Vol. 76. — P. 103530. — doi.org/10.1016/j.scs.2021.103530.
 9. Li, S. Double-layer energy management system based on energy sharing cloud for virtual residential microgrid / S. Li, J. Zhu, Z. Chen, T. Luo // *Applied Energy*. — 2021. — Vol. 282. — P. 116089. — doi.org/10.1016/j.apenergy.2020.116089.
 10. Jasim, A.M. A new optimized demand management system for smart grid-based residential buildings adopting renewable and storage energies / A.M. Jasim, B.H. Jasim, A. Flah, V. Bolshev, L. Mihet-Popa // *Energy Reports*. — 2023. — Vol. 9. — P. 4018-4035. — doi.org/10.1016/j.egy.2023.03.038.
 11. Duman, A. C. A home energy management system with an integrated smart thermostat for demand response in smart grids / A. C. Duman, A. C. Erden, . G n l, . G ler // *Sustainable Cities and Society*. — 2021. — Vol. 65. — P. 102639. — doi.org/10.1016/j.scs.2020.102639.
 12. Aliero, M.S. Smart Home Energy Management Systems in Internet of Things networks for green cities demands and services / M.S. Aliero, K.N. Qureshi, M.F. Pasha, G. Jeon // *Environmental Technology & Innovation*. — 2021. — Vol. 22. — P. 101443. — doi.org/10.1016/j.eti.2021.101443.
 13. Gon alves, I. Optimizing the management of smart home energy resources under different power cost scenarios / I. Gon alves, . Gomes, C.H. Antunes // *Applied Energy*. — 2019. — Vol. 242. — P. 351-363. — doi.org/10.1016/j.apenergy.2019.03.108.
 14. Sorokin, I.V. Analysis of the experience of applying machine learning methods in the Russian construction industry / I.V. Sorokin, A.V. Nastychuk // *Construction and Architecture*. — 2023. — Vol. 11. — No. 1(38). — P. 18. — DOI 10.29039/2308-0191-2022-11-1-18-18.
 15. Park, K. Multi-agent deep reinforcement learning approach for EV charging scheduling in a smart grid / K. Park, I. Moon // *Applied Energy*. — 2022. — Vol 328. — P. 120111. — doi.org/10.1016/j.apenergy.2022.120111.
 16. Wang, Y. Cooperative energy management and eco-driving of plug-in hybrid electric vehicle via multi-agent reinforcement learning / Y. Wang, Y. Wu, Y. Tang, Q. Li, H. He // *Applied Energy*. — 2023. — Vol. 332. — P. 120563. — doi.org/10.1016/j.apenergy.2022.120563.
 17. Lehna, M. Forecasting day-ahead electricity prices: A comparison of time series and neural network models taking external regressors into account / M. Lehna, F. Scheller, H. Herwartz // *Energy Economics*. — 2022. — Vol. 106. — P. 105742. — doi.org/10.1016/j.eneco.2021.105742.
 18. Keles, D. Extended forecast methods for day-ahead electricity spot prices applying artificial neural networks / D. Keles, J. Scelle, F. Paraschiv, W. Fichtner // *Applied Energy*. — 2016. — Vol. 162. — P. 218-230. — doi.org/10.1016/j.apenergy.2015.09.087.