



<http://dx.doi.org/10.35596/1729-7648-2025-31-3-22-32>

УДК 004; 004.932

РАЗРАБОТКА МОДЕЛИ МАШИННОГО ОБУЧЕНИЯ ДЛЯ СИСТЕМЫ «УМНЫЙ ДОМ»

М. М. ЛУКАШЕВИЧ

*Белорусский государственный университет (Минск, Республика Беларусь)
Белорусский государственный университет информатики и радиоэлектроники
(Минск, Республика Беларусь)*

Аннотация. Машинное обучение повышает эффективность использования систем «умный дом», позволяет конструкциям домашней автоматизации регулировать отопительную и охлаждающую системы, освещение, температуру помещения и другие параметры. Вариабельность данных и совершенствование таких систем требуют постоянного расширения наборов данных, переобучения или дообучения моделей машинного обучения, модификации алгоритмов и архитектур. В статье представлены модели прогнозирования тепловой и охлаждающей нагрузок дома на основе методов машинного обучения. Приведены результаты исследовательского анализа данных, построения моделей регрессии для прогнозирования загрузки отопительной и охлаждающей систем. Показана эффективность подбора значений гиперпараметров на основе метода поиска по решетке. Рассмотрена нейросетевая модель, позволяющая одновременно прогнозировать загрузку отопительной и охлаждающей систем. Выполнены оценка точности и сравнение моделей на основе метрик качества регрессии.

Ключевые слова: машинное обучение, регрессия, исследовательский анализ данных, алгоритм машинного обучения, модель машинного обучения, метрики оценки качества.

Конфликт интересов. Автор заявляет об отсутствии конфликта интересов.

Для цитирования. Лукашевич, М. М. Разработка модели машинного обучения для системы «умный дом» / М. М. Лукашевич // Цифровая трансформация. 2025. Т. 31, № 3. С. 22–32. <http://dx.doi.org/10.35596/1729-7648-2025-31-3-22-32>.

DEVELOPING A MACHINE LEARNING MODEL FOR A SMART HOME SYSTEM

MARINA M. LUKASHEVICH

*Belarusian State University (Minsk, Republic of Belarus)
Belarusian State University of Informatics and Radioelectronics (Minsk, Republic of Belarus)*

Abstract. Machine learning improves the efficiency of smart home systems, allows home automation systems to regulate heating and cooling systems, lighting, room temperature and other parameters. Data variability and improvement of such systems require constant expansion of data sets, retraining or additional training of machine learning models, modification of algorithms and architectures. The article presents models for predicting heating and cooling loads of a house based on machine learning methods. The results of exploratory data analysis, construction of regression models for predicting the load of heating and cooling systems are presented. The efficiency of selecting hyperparameter values based on the grid search method is shown. A neural network model is considered that allows simultaneous prediction of the load of heating and cooling systems. The accuracy is assessed and the models are compared based on regression quality metrics.

Keywords: machine learning, regression, exploratory data analysis, machine learning algorithm, machine learning model, quality assessment metrics.

Conflict of interests. The author declares no conflict of interests.

For citation. Lukashevich M. M. (2025) Developing a Machine Learning Model for a Smart Home System. *Digital Transformation*. 31 (3), 22–32. <http://dx.doi.org/10.35596/1729-7648-2025-31-3-22-32> (in Russian).

Введение

Интеграция машинного обучения в системы автоматизации «умный дом» является перспективным направлением и дает пользователям ряд преимуществ – корректировать настройки в соответствии с окружающей средой, поведением и требованиями пользователя. Машинное обучение улучшает эффективность систем «умный дом», позволяет системам домашней автоматизации регулировать отопительную и охлаждающую системы, освещение, температуру помещения и другие параметры. В настоящее время непрерывно совершенствуются как сами системы «умный дом», так и всевозможные датчики, что требует разработки новых эффективных моделей машинного обучения для решения широкого круга задач автоматизации домашних систем.

Наряду с преимуществами машинного обучения, есть несколько существенных ограничений, а именно: необходимость большого объема данных и значительная вычислительная мощность. Кроме того, в системе «умный дом» присутствуют постоянные изменения в окружающей среде, а, соответственно, и в данных для обучения моделей машинного обучения. Это требует постоянного расширения наборов данных, переобучения или дообучения моделей, совершенствования алгоритмов и архитектур [1, 2].

Процесс разработки моделей машинного обучения

Процесс построения моделей машинного обучения включает в себя следующие этапы. Первый – это постановка задачи в терминах машинного обучения, определение метрик для оценки качества моделей. Второй этап включает получение или сбор данных. Часто при решении научных задач целесообразно воспользоваться релевантными публичными наборами данных. Третий этап – исследовательский анализ данных (Exploratory Data Analysis, EDA). Иногда используется термин «разведочный анализ данных». На этой стадии исследуется мощность набора данных, изучаются признаки, описывающие объект, устанавливаются их отличия и взаимосвязи, выполняется визуализация данных. На основе результатов исследовательского анализа данных определяется четвертый этап – обработка данных, которая может включать очистку данных (устранение дубликатов, заполнение пропусков и др.), масштабирование признаков, кодирование категориальных переменных, конструирование и отбор признаков, понижение размерности, подготовку обучающего, тестового и валидационного наборов. Пятый этап является непосредственно этапом построения моделей машинного обучения и оценки результатов. Заключительный, или шестой этап, – развертывание моделей машинного обучения в производственной среде. Описанный процесс итерационный, на каждом этапе при получении неудовлетворительных результатов может возникнуть необходимость вернуться к предыдущим этапам, усовершенствовать их, включить дополнительные данные, операции, алгоритмы и др. (рис. 1) [3, 4].




Рис. 1. Процесс разработки модели машинного обучения
Fig. 1. The process of developing a machine learning model

Целью исследований являлось построение моделей прогнозирования тепловой и охлаждающей нагрузок дома на основе методов машинного обучения. При эффективном проектировании

здания расчет тепловой и охлаждающей нагрузок нужен для определения технических характеристик отопительного и охлаждающего оборудования, необходимого для поддержания комфортных условий воздуха в помещении. В терминах машинного обучения это является задачей регрессии.

Исследовательский анализ данных

Цель исследовательского анализа данных – понимание структуры и характеристик набора данных, выявление аномалий и выбросов, идентификация связей и корреляций между переменными, подготовка данных для дальнейших этапов анализа. Для оценки мощности охлаждения и обогрева помещения необходима информация о характеристиках здания и кондиционируемого пространства (например, заполняемость и уровень активности).

Для проведения экспериментов был выбран публичный набор данных, в котором представлена информация о 768 объектах (12 типов различных зданий), описанных десятью признаками. Исследовательский анализ данных выполнялся средствами библиотеки pandas. Процедура проведения регрессионного анализа заключается в определении математической модели в форме уравнения (функция регрессии) $y = f(x_1, x_2, x_3, \dots, x_m)$, устанавливающей функциональную связь между зависимой переменной y и группой независимых переменных $x_1, x_2, x_3, \dots, x_m$ с учетом ошибки модели ε . Применение регрессионного анализа оправдано при наличии выборки данных, из которой можно выделить зависимую и ряд независимых переменных. Полученная подобным образом модель позволяет оценивать и прогнозировать изменение зависимой переменной от группы независимых в различных состояниях [5, 6].

Исходя из формулировки задачи регрессии, восемь переменных (относительная компактность (Relative Compactness), площадь поверхности (Surface Area), площадь стен (Wall Area), площадь крыши (Roof Area), общая высота (Overall Height), ориентация (Orientation), площадь остекления (Glazing Area), распределение площади остекления (Glazing Area Distribution)) являются независимыми (факторы, оказывающие влияние на зависимую переменную). Загрузка отопительной (Heating Load) и охлаждающей (Cooling Load) систем – значения зависимых переменных (отклик) для каждого отдельного наблюдения. Признаки «загрузка отопительной системы» и «загрузка охлаждающей системы» являются целевыми при построении моделей регрессии для предсказания загрузки отопительной и охлаждающей систем соответственно. Признаки и их основные статистические характеристики для пяти первых объектов набора данных представлены на рис. 2.

	Относительная компактность	Площадь поверхности	Площадь стен	Площадь крыши	Общая высота	Ориентация	Площадь остекления	Распределение площади остекления	Загрузка отопительной системы	Загрузка охлаждающей системы
0	0,98	514,50	294,00	110,25	7,00	2.0	0,00	0.0	15,55	21,33
1	0,98	514,50	294,00	110,25	7,00	3.0	0,00	0.0	15,55	21,33
2	0,98	514,50	294,00	110,25	7,00	4.0	0,00	0.0	15,55	21,33
3	0,98	514,50	294,00	110,25	7,00	5.0	0,00	0.0	15,55	21,33
4	0,90	563,50	318,50	122,50	7,00	2.0	0,00	0.0	20,84	28,28

Рис. 2. Первые пять объектов из исследуемого набора данных
Fig. 2. The first five objects in the dataset

Сводные статистики, позволяющие получить обобщенное представление о распределении данных и об основных характеристиках, а также отражающие типичные и наиболее значимые значения в наборе данных, представлены на рис. 3, а. На рис. 3, б приведена информация о числе объектов в наборе данных, типах признаков, описывающих объект, а также об отсутствии пропущенных и нулевых значений.

Корреляционный анализ выявляет взаимосвязи их признаков между собой. Коэффициент корреляции отражает степень линейной зависимости между двумя признаками. На рис. 4 представлена тепловая карта, которая отображает корреляцию между признаками.

В процессе экспериментов использована визуализация данных для определения трендов и взаимосвязей в них. На рис. 5 изображены диаграммы рассеяния, отображающие взаимодейст-

вие между признаками. На рис. 6 представлены диаграммы размаха – «ящики с усами», визуализирующие статистические характеристики распределения данных (медиана, квантили и выбросы) и отображающие разброс и симметрию данных, а также возможные аномалии. Зависимости загрузки холодильной и отопительной систем от плотности показаны на рис. 7.




Рис. 3. Основная информация по набору данных:

a – сводные статистики набора данных; *b* – информация о признаках, описывающих объект

Fig. 3. Basic information about the dataset:

a – summary statistics of the dataset; *b* – information about features describing the object




Рис. 4. Тепловая карта, отображающая корреляцию между признаками

Fig. 4. Heat map showing the correlation between features

В процессе исследовательского анализа данных установлено, что их набор содержит только числовые признаки, категориальных признаков нет. Определено, что пропущенных данных, данных с не определенным значением и категориальных переменных нет. Сводные статистики позволяют получить обобщенное представление о распределении данных и об основных характеристиках, дают понимание о наиболее типичных и значимых значениях в наборе. Выбросов и аномалий здесь нет. Данные перед этапом построения модели машинного обучения необходимо масштабировать. Иных этапов их обработки не требуется.




Рис. 5. Диаграммы рассеяния, отображающие взаимодействие между признаками
Fig. 5. Scatter plots showing the interaction between features




Рис. 6. «Ящики с усами», визуализирующие статистические характеристики данных и возможные аномалии
Fig. 6. “Boxes with whiskers” visualizing statistical characteristics of the data and possible anomalies




Рис. 7. Зависимость загрузки охладительной и отопительной систем от плотности

Fig. 7. Dependence of the loading of cooling and heating systems on density

Разработка моделей машинного обучения

Для построения моделей регрессии выбраны алгоритмы машинного обучения, приведенные в табл. 1 [7–11].

Таблица 1. Алгоритмы для построения моделей регрессии

Table 1. Algorithms for regression model development

Алгоритм	Краткое название алгоритма
Линейная регрессия	LinearRegressor
Дерево решений	DecisionTreeRegressor
k ближайших соседей	KNeighborsRegressor
Машины опорных векторов	SVR
Градиентный бустинг	GradientBoostingRegressor
Случайный лес	RandomForestRegressor

Для подготовки тестового и обучающего наборов, реализации выбранных алгоритмов, оценки их качества использовалась библиотека `scikit-learn`. Значения гиперпараметров алгоритмов не настраивались и использовались по умолчанию из библиотеки `scikit-learn`. Исходный набор данных был разделен на обучающую и тестовую выборки (70 и 30 % соответственно). Выбран подход нормализации, при котором данные масштабируются до диапазона от 0 до 1 путем преобразования с использованием минимального и максимального значений признака. Переменные Heating Load и Cooling Load являются зависимыми и фактически будут выходами модели регрессии. Указанные в табл. 1 алгоритмы позволяют построить модель с одной зависимой переменной. Поэтому каждый алгоритм будет использован для построения двух моделей, предсказывающих значения переменных Heating Load и Cooling Load.

Сравнение построенных моделей по метрикам качества помогает объективно выбрать лучшую модель среди предложенных. Сравнивая производительность представленных моделей, можно определить ту, которая обеспечивает лучший результат для описанной проблемы. Метриками качества регрессионных моделей были следующие коэффициенты: средняя абсолютная ошибка (Mean Absolute Error, MAE), среднеквадратическая ошибка (Mean, Squared Error, MSE), коэффициент детерминации R -квадрат (R^2).

MAE измеряет среднюю абсолютную разницу между прогнозируемыми значениями и фактическими. Она отражает меру того, насколько в среднем предсказания модели близки к истин-

ным значениям. MSE подчеркивает меру того, насколько хорошо прогнозы модели согласуются с истинными значениями. Более низкие значения указывают на лучшую производительность. R -квадрат показывает долю дисперсии зависимой переменной, объясненной при помощи регрессионной модели. Если $R^2 = 0$, то регрессионная модель не объясняет никаких изменений зависимой переменной, если $R^2 = 1$, то объясняет. Коэффициент R^2 представляет собой долю общей изменчивости зависимой переменной, учитываемую регрессионной моделью, а также показывает, насколько хорошо модель фиксирует закономерности и взаимосвязи в данных. Эта метрика лучше позволяет получить относительные оценки точности регрессии, а другие две метрики дают абсолютные оценки, что не всегда наглядно.

Результаты тестирования регрессионных моделей на тестовом наборе данных

Результаты оценки точности построенных регрессионных моделей на основе алгоритмов, представленных в табл. 1, приведены в табл. 2 и 3. Оценки получены для независимых тестовых данных, а модели обучены на обучающем наборе. Лучшие результаты показывают модели на основе случайного леса для прогнозирования загрузки отопительной системы ($R^2 = 0,9978$) и на основе градиентного бустинга для прогнозирования загрузки охлаждающей системы ($R^2 = 0,9747$).

Таблица 2. Точность регрессионных моделей для прогнозирования загрузки отопительной системы
Table 2. Accuracy of regression models for predicting heating system load

Модель	MAE	MSE	R^2
LinearRegressor	2,1374	9,2336	0,9116
DecisionTreeRegressor	0,3726	0,3023	0,9971
KNeighborsRegressor	2,0421	9,7218	0,9070
SVR	2,0540	9,3331	0,9107
GradientBoostingRegressor	0,3593	0,2422	0,9976
RandomForestRegressor	0,3390	0,2294	0,9978

Таблица 3. Точность регрессионных моделей для прогнозирования загрузки охлаждающей системы
Table 3. Accuracy of regression models for predicting cooling system load

Модель	MAE	MSE	R^2
LinearRegressor	2,2699	10,0687	0,8886
DecisionTreeRegressor	1,1166	4,7207	0,9477
KNeighborsRegressor	2,2793	10,0495	0,8888
SVR	2,2754	10,5151	0,8837
GradientBoostingRegressor	1,0408	2,2869	0,9747
RandomForestRegressor	1,0863	3,3645	0,9627

Подбор гиперпараметров регрессионных моделей, оценка точности на тестовом наборе данных

Для улучшения качества работы моделей выполнен подбор отдельных гиперпараметров методом поиска по решетке. В табл. 4 представлены перечень гиперпараметров, значения гиперпараметров по умолчанию при первичном построении моделей и диапазон поиска. Для модели линейной регрессии подбор гиперпараметров не выполнялся в силу крайней простоты модели и низкой точности на тестовом наборе со значениями гиперпараметров по умолчанию. Лучшие значения гиперпараметров, а также комбинация значений определялись на основе оценки точности регрессии с использованием метрики R^2 . Подбор гиперпараметров регрессионных моделей для оценки точности прогнозирования загрузки отопительной и охлаждающей систем проводился независимо (табл. 5, 6). Результаты тестирования регрессионных моделей с выбранными значениями гиперпараметров приведены в табл. 7, 8.

Таблица 4. Данные по гиперпараметрам и диапазон поиска
Table 4. Hyperparameter data and search range

Модель	Гиперпараметр	Значение гиперпараметра по умолчанию	Диапазон поиска
DecisionTreeRegressor	"criterion"	"squared_error"	["squared_error", "absolute_error"]
	"min_samples_split"	default=2	[14, 15, 16, 17]
	"max_depth"	default=None	[5, 10, 15, 20, 25, 30, 35, 40, 45, 50, 55, 60, 65, 70, 85, 90, 95]
	"min_samples_leaf"	default=1	[4, 5, 6]
	"max_leaf_nodes"	default=None	[29, 30, 31, 32]
KNeighborsRegressor	"n_neighbors"	default=5	[3, 5, 7, 9, 11]
	"weights"	default="uniform"	["uniform", "distance"]
	"algorithm"	default="auto"	["auto", "ball_tree", "kd_tree", "brute"]
SVR	"kernel"	default="rbf"	["linear", "poly", "rbf", "sigmoid"]
GradientBoostingRegressor	"n_estimators"	default=100	[5, 10, 15, 20, 50, 100, 150, 200, 250, 300, 350, 400]
	"max_features"	default=None	[1, 2]
	"max_depth"	default=3	[5, 10, 15, 20, 25, 30, 35, 40, 45, 50, 55, 60, 65, 70, 85, 90, 95]
RandomForestRegressor	"n_estimators"	default=100	[5, 10, 15, 20, 50, 100, 150, 200, 250, 300, 350, 400]
	"max_features"	default=1.0	[1, 2]
	"max_depth"	default=None	[5, 10, 15, 20, 25, 30, 35, 40, 45, 50, 55, 60, 65, 70, 85, 90, 95]

Таблица 5. Результаты подбора гиперпараметров
для регрессионной модели прогнозирования загрузки отопительной системы
Table 5. Results of hyperparameter selection for the regression model for prediction of heating system loading

Модель	Лучшее значение R^2	Значение гиперпараметра
DecisionTreeRegressor	0,9900	{"criterion": "squared_error", "min_samples_split": 15 "max_depth": 60 "min_samples_leaf": 5 "max_leaf_nodes": 32}
KNeighborsRegressor	0,9206	{"algorithm": "ball_tree", "n_neighbors": 7, "weights": "uniform"}
SVR	0,9399	{"kernel": "poly"}
GradientBoostingRegressor	0,9974	{"max_depth": 5, "max_features": 2, "n_estimators": 400 }
RandomForestRegressor	0,9929	{"max_depth": 70, "max_features": 2, "n_estimators": 200}

Таблица 6. Результаты подбора гиперпараметров
для регрессионной модели прогнозирования загрузки охлаждающей системы
Table 6. Results of hyperparameter selection of the regression model for prediction of cooling system loading

Модель	Лучшее значение R^2	Значение гиперпараметра
DecisionTreeRegressor	0,9900	{"criterion": "squared_error", "min_samples_split": 17 "max_depth": 10 "min_samples_leaf": 5 "max_leaf_nodes": 32}

Окончание табл. 6
Ending of Tab. 6

Модель	Лучшее значение R^2	Значение гиперпараметра
KNeighborsRegressor	0,9206	{“algorithm” : “ball_tree”, “n_neighbors” : 7, “weights” : “uniform”}
SVR	0,9399	{“kernel” : “poly”}
GradientBoostingRegressor	0,9974	{“max_depth” : 5, “max_features” : 2, “n_estimators” : 350 }
RandomForestRegressor	0,9929	{“max_depth” : 65, “max_features” : 1, “n_estimators” : 100}

Таблица 7. Точность регрессионных моделей для оценки прогнозирования загрузки отопительной системы с подобранными значениями гиперпараметров
Table 7. Accuracy of regression models for assessing the forecasting of the heating system load with selected hyperparameter values

Модель	MAE	MSE	R^2
DecisionTreeRegressor	0,4640	0,4424	0,9957
KNeighborsRegressor	1,9528	8,4298	0,9182
SVR	1,6404	7,0775	0,9313
GradientBoostingRegressor	0,2829	0,1514	0,9985
RandomForestRegressor	0,4839	0,3951	0,9961

Таблица 8. Точность регрессионных моделей для оценки прогнозирования загрузки охлаждающей системы с подобранными значениями гиперпараметров
Table 8. Accuracy of regression models for assessing the forecasting of cooling system load with selected hyperparameter values

Модель	MAE	MSE	R^2
DecisionTreeRegressor	0,3726	0,3023	0,9971
KNeighborsRegressor	2,0421	9,7218	0,9070
SVR	2,0540	9,3331	0,9107
GradientBoostingRegressor	0,3593	0,2422	0,9976
RandomForestRegressor	0,3390	0,2294	0,9978

Лучшие результаты показывает модель на основе градиентного бустинга для прогнозирования загрузки отопительной системы ($R^2 = 0,9985$). Также видно увеличение точности модели в сравнении с моделями, разработанными с дефолтными значениями гиперпараметров. Лучшие результаты для прогнозирования загрузки охлаждающей системы показывает модель на основе случайного леса ($R^2 = 0,9978$). Точность моделей с дефолтными значениями гиперпараметров была ниже. Для модели на основе градиентного бустинга оценка точности составляла $R^2 = 0,9747$.

Нейросетевая модель регрессии

Представленные выше модели показывают высокую точности и могут быть использованы для решения практических задач прогнозирования загрузки отопительной и охлаждающей систем «умного дома». Однако с точки зрения развертывания моделей в производственной среде идентичный вектор данных поступает на две модели, которые независимо друг от друга прогнозируют загрузку отопительной и охлаждающей систем. Это требует использования двух моделей, что не всегда целесообразно с точки зрения вычислительных и временных затрат. Целесообразной же проставляется разработка одной модели, прогнозирующей загрузку отопительной и охлаждающей систем. Для устранения этого недостатка была разработана нейросетевая модель, включающая в себя один входной слой и два выходных значения. Эти значения будут соответствовать прогнозным значениям загрузки отопительной и охлаждающей систем. В целом

нейросетевая модель состоит из полносвязных слоев и разработана с использованием фреймворка Keras. Структура модели представлена на рис. 8.

Model: "model"

Layer (type)	Output Shape	Param #	Connected to
input_1 (InputLayer)	[(None, 8)]	0	[]
dense (Dense)	(None, 128)	1152	['input_1[0][0]']
dense_1 (Dense)	(None, 128)	16512	['dense[0][0]']
dense_2 (Dense)	(None, 64)	8256	['dense_1[0][0]']
y1_output (Dense)	(None, 1)	129	['dense_1[0][0]']
y2_output (Dense)	(None, 1)	65	['dense_2[0][0]']

=====

Total params: 26114 (102.01 KB)
Trainable params: 26114 (102.01 KB)
Non-trainable params: 0 (0.00 Byte)

Рис. 8. Структура нейросетевой модели
Fig. 8. Neural network model structure

При обучении модели использовался оптимизатор на основе статистического градиентного спуска (SGD). MSE использовалась как функция потерь, а в качестве метрики оценки точности модели – метрика R^2 . Обучение проходило в течение 500 эпох, размер батча – 10 образцов. Обучение проводилось на тех же образцах, что и в предыдущих разделах, точность модели оценивалась на идентичном тестовом наборе. Точность прогнозирования загрузки отопительной системы $R^2 = 0,9981$, а охлаждающей – $R^2 = 0,9910$, что незначительно отличается от эффективности моделей, представленных в предыдущих разделах.

Заключение

1. Приведено решение прикладной задачи на основе машинного обучения. Представлены результаты исследовательского анализа данных, построение моделей регрессии для прогнозирования загрузки отопительной и охлаждающей систем для системы «умный дом». Показана эффективность подбора значений гиперпараметров на основе метода поиска по решетке, что позволило улучшить точность моделей регрессии.

2. Точность моделей регрессии вычислялась на независимом тестовом наборе данных с применением стандартных метрик оценки качества регрессии. Лучшие результаты показали модели на основе градиентного бустинга ($R^2 = 0,9985$) для прогнозирования загрузки отопительной системы и на основе случайного леса ($R^2 = 0,9978$) для прогнозирования загрузки охлаждающей системы.

3. Дано описание нейросетевой регрессионной модели, позволяющей спрогнозировать загрузку отопительной и охлаждающей систем ($R^2 = 0,9981$ и $R^2 = 0,9910$ соответственно). Нейросетевая модель позволяет одновременно спрогнозировать загрузку отопительной и охлаждающей систем. Такой подход учитывает связи между процессами отопления и охлаждения, а также сокращает количество моделей до одной, что уменьшит затраты на обучение и поддержание модели, а также инфраструктуру в целом. Одну модель проще интегрировать в производственную среду, обновлять и тестировать.

Список литературы

- Грингард, С. Интернет вещей: будущее уже здесь / С. Грингард; 2-е изд. М.: Альпина Паблишер, 2019.
- Попов, Е. В. Умные города / Е. В. Попов, К. А. Семячков. М.: Изд-тво Юрайт, 2020.
- Жерон, О. Прикладное машинное обучение с помощью Scikit-Learn, Keras и TensorFlow / О. Жерон; 2-е изд. М.: Диалектика, 2020.
- Маккинни, У. Python и анализ данных / У. Маккинни; пер. с англ. А. А. Слинкина; 2-е изд., испр. и доп. М.: ДМК Пресс, 2020.
- Курлов, А. Б. Методология информационной аналитики / А. Б. Курлов, В. К. Петров. М.: Проспект, 2014.

6. Prediction a Building's Energy Efficiency [Electronic Resource]. Mode of access: <https://www.kaggle.com/code/jarredpriester/predicting-a-building-s-energy-efficiency>. Date of access: 01.11.2023.
7. Polikar, R. Ensemble Based Systems in Decision Making / R. Polikar // IEEE Circuits and Systems Magazine. 2006. Vol. 6, No 3. P. 21–45. DOI: 10.1109/mcas.2006.1688199.
8. Rokach, L. Ensemble Methods for Classifiers / L. Rokach // Data Mining and Knowledge Discovery Handbook. 2025. P. 957–980. DOI: 10.1007/0-387-25465-x_45.
9. Kuncheva, L. I. Measures of Diversity in Classifier Ensembles and Their Relationship with the Ensemble Accuracymachine Learning / L. I. Kuncheva, C. J. Whitaker // Machine Learning. 2003. Vol. 51, No 2. P. 181–207. DOI: 10.1023/a:1022859003006.
10. Chin-Wei, Hsu. A Practical Guide to Support Vector Classification / Chin-Wei Hsu, Chih-Chung Chang, Chih-Jen Lin // Technical Report, National Taiwan University. 2010.
11. Chicco, D. Ten Quick Tips for Machine Learning in Computational Biology / D. Chicco // BioData Mining. 2017. Vol. 35, No 10. 35. DOI: 10.1186/s13040-017-0155-3.

Поступила 16.05.2025

Принята в печать 15.07.2025

Доступна на сайте 10.10.2025

References

1. Greengard S. (2019) *Internet of Things: The Future is Already Here*. Moscow, Alpina Publisher (in Russian).
2. Popov E. V., Semyachkov K. A. (2020) *Smart Cities*. Moscow, Yurait Publishing House (in Russian).
3. Giron O. (2020) *Applied Machine Learning with Scikit-Learn, Keras and TensorFlow*. Moscow, Dialectics Publ. (in Russian).
4. McKinney W. (2020) *Python and Data Analysis*. Moscow, DMK Press Publ. (in Russian).
5. Kurlov A. B., Petrov V. K. (2014) *Methodology of Information Analytics: A Monograph*. Moscow, Prospect Publ. (in Russian).
6. Prediction a Building's Energy Efficiency. Available: <https://www.kaggle.com/code/jarredpriester/predicting-a-building-s-energy-efficiency> (Accessed 1 November 2023).
7. Polikar R. (2006) Ensemble Based Systems in Decision Making. *IEEE Circuits and Systems Magazine*. 6 (3), 21–45. DOI: 10.1109/mcas.2006.1688199.
8. Rokach L. (2025) Ensemble Methods for Classifiers. *Data Mining and Knowledge Discovery Handbook*. 957–980. DOI: 10.1007/0-387-25465-x_45.
9. Kuncheva L. I., Whitaker C. J. (2003) Measures of Diversity in Classifier Ensembles and Their Relationship with the Ensemble Accuracymachine Learning. *Machine Learning*. 51 (2), 181–207. DOI: 10.1023/a:1022859003006.
10. Chin-Wei Hsu, Chih-Chung Chang, Chih-Jen Lin (2010) A Practical Guide to Support Vector Classification. *Technical Report, National Taiwan University*.
11. Chicco D. (2017) Ten Quick Tips for Machine Learning in Computational Biology. *BioData Mining*. 35 (10). DOI: 10.1186/s13040-017-0155-3.

Received: 16 May 2025

Accepted: 15 July 2025

Available on the website: 10 October 2025

Сведения об авторе

Лукашевич М. М., канд. техн. наук, доц. Белорусского государственного университета, докторант Белорусского государственного университета информатики и радиоэлектроники

Адрес для корреспонденции

220013, Республика Беларусь,
Минск, ул. Платонова, 39
Белорусский государственный университет
информатики и радиоэлектроники
Тел.: +375 17 293-86-17
E-mail: lukashevich@bsuir.by
Лукашевич Марина Михайловна

Information about the author

Lukashevich M. M., Cand. Sci. (Tech.), Associate Professor at the Belarusian State University, Doctoral Student of the Belarusian State University of Informatics and Radioelectronics

Address for correspondence

220013, Republic of Belarus,
Minsk, Platonova St., 39
Belarusian State University
of Informatics and Radioelectronics
Tel.: +375 17 293-86-17
E-mail: lukashevich@bsuir.by
Lukashevich Marina Mikhailovna