

УДК 64.066.22

**МЕТОДИКА НЕЙРОСЕТЕВОГО ПРОГНОЗИРОВАНИЯ
ЭНЕРГОПОТРЕБЛЕНИЯ ДЛЯ УСТОЙЧИВОГО РАЗВИТИЯ УМНОЙ
ГОРОДСКОЙ СРЕДЫ**

Кузнецов П.Н.

К.т.н., доцент кафедры «Возобновляемые источники энергии и электрические системы и сети»,

ФГАОУ ВО «Севастопольский государственный университет»,

РФ, г. Севастополь

Котельников Д.Ю.

студент,

ФГАОУ ВО «Севастопольский государственный университет»,

РФ, г. Севастополь

Воронин Д.Ю.

К.т.н., заведующий базовой кафедрой «Программная инженерия интеллектуальных систем»,

ФГАОУ ВО «Севастопольский государственный университет»,

РФ, г. Севастополь

Хомюк А.Г.

студент,

ФГАОУ ВО «Севастопольский государственный университет»,

РФ, г. Севастополь

Аннотация. Важным аспектом развития умной городской среды является совершенствование и внедрение интеллектуальных технологий распределения электроэнергии, способных, с одной стороны гарантированно обеспечивать возрастающие потребности к ее качеству, надежности и доступности, а с другой – соответствовать базовым принципам устойчивого развития (экологическим, экономическим и социальным). В частности, для эффективного внедрения технологии интеллектуальных активно-адаптивных сетей «SmartGrid» требуется создание развитых технологий прогнозирования энергопотребления в микро- и мезомасштабе. Интенсивное развитие умной городской среды вносит существенную неопределенность при принятии решений о рациональном энергоснабжении гетерогенных объектов, имеющих географическую и функциональную распределенность. Вышеуказанные тенденции обуславливают необходимость разработки и внедрения методик прогнозирования энергопотребления, способствующих устойчивому развитию умной городской среды. В статье предлагается методика нейросетевого прогнозирования энергопотребления. Результаты проведенных вычислительных экспериментов показывают, что использование нейронных сетей глубокого обучения позволяет с довольно точностью около 95 % выявлять зависимости в графиках энергопотребления.

Ключевые слова: энергопотребление, умный город, нейронные сети, SmartGrid, устойчивое развитие, методика прогнозирования.

***NEURAL NETWORK FORECASTING TECHNIQUE
ENERGY CONSUMPTION FOR SUSTAINABLE DEVELOPMENT OF A
SMART CITY ENVIRONMENT***

Kuznetsov P.N.

*Ph.D., Associate Professor, Department of Renewable Energy and Electrical
Systems and Networks,
Sevastopol State University,
Russian Federation, Sevastopol*

Kotelnikov D.Yu.

*Student,
Sevastopol State University,
Russian Federation, Sevastopol*

Voronin D.Yu.

*Ph.D., head of the base department "Software Engineering of Intelligent Systems",
Sevastopol State University,
RF, Sevastopol*

Номыук А.Г.

*Student,
Sevastopol State University,
Russian Federation, Sevastopol*

Abstract An important aspect of the smart urban environment development is the improvement and implementation of intelligent technologies for the electricity distribution, which are able, on the one hand, to provide guaranteed growing needs for its quality, reliability and affordability, and on the other, to comply with the basic principles of sustainable development (environmental, economic and social). In particular, for the effective implementation of SmartGrid technology of intelligent active adaptive networks, the development of advanced technologies for predicting energy consumption on a micro- and mesoscale is required. The intensive development of a smart urban environment introduces significant uncertainty when making decisions on the rational energy supply of heterogeneous objects with a geographical and functional distribution. The above trends determine the need for the development and implementation of energy consumption forecasting techniques that contribute to the sustainable development of a smart urban environment. The article proposes a methodology for neural network prediction of energy consumption. The results of the computational experiments show that the use of deep learning neural networks allows with fairly accurate about 95% to identify dependencies in energy consumption graphs.

Keywords: energy consumption, smart city, neural networks, SmartGrid, sustainable development, forecasting technique

Проактивная методология цифровой трансформации подразумевает необходимость реконфигурации распределенных сетей энергоснабжения, используя научные идеи и перспективные технологии, отраженные в «дорожной карте» Национальной технологической инициативы «Энерджинет». В частности, для эффективного внедрения технологии интеллектуальных активно-адаптивных сетей «SmartGrid» требуется создание развитых технологий прогнозирования энергопотребления в микро- и мезомасштабе. Такой переход предполагает увеличение масштабов использования распределенной генерации, требующей интеллектуального децентрализованного управления, обеспечивая свободный обмен электроэнергией между потребителями, генерирующими компаниями и просьюмерами [1-3]. Эти обстоятельства направлены на формирование технических решений, соответствующих базовым принципам устойчивого развития городской среды, подразумевают использование современных сквозных информационных технологий для повышения эффективности использования природных ресурсов и улучшения технико-экономических показателей электроэнергетической отрасли [4,5].

Рост мирового энергопотребления зависит от различных тенденций: повышение интенсивности производства, увеличение объемов потребляемой энергии (ввиду усложнения производственных циклов), урбанизации, индустриализации и глобализации. Кроме того, интенсивное развитие умной городской среды вносит существенную неопределенность при принятии решений о рациональном энергоснабжении гетерогенных объектов, имеющих географическую и функциональную распределенность. Вышеуказанные тенденции обуславливают необходимость разработки и внедрения методик прогнозирования энергопотребления, способствующих устойчивому развитию умной городской среды.

Целью исследования является разработка алгоритма прогнозирования энергопотребления, базирующегося на реальных значениях нагрузки потребителей различных типов.

В ходе исследования требуется решить следующие задачи:

1. Рассмотреть возможность использования журналов нагрузки современного интеллектуального электросетевого оборудования, включающего датчики напряжения и тока, имеющие точность достаточную для коммерческого учета, в качестве основного источника информации об энергопотреблении.

2. Проанализировать существующие методы обработки данных энергопотребления с целью выявления зависимостей (паттернов).

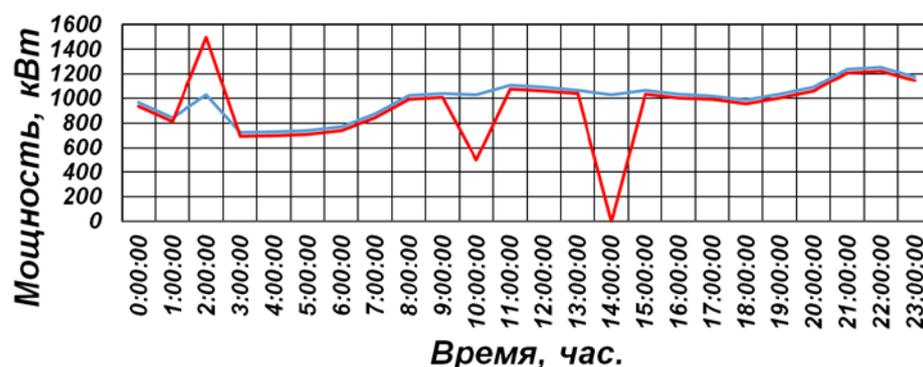
3. Разработать методику и способ прогнозирования суточной динамики энергопотребления на основе выявленных зависимостей.

4. При помощи современных инструментальных средств реализовать разработанный способ и оценить его эффективность на основе реальных данных суточной динамики энергопотребления распределительной сети.

Проанализировав перспективные пути решения рассматриваемых задач, можно сделать вывод, что некоторые аспекты прогнозирования энергопотребления рассмотрены недостаточно подробно – кластеризация данных потребления электрической энергии, а также последующая классификация и идентификация потребителей согласно их динамике энергопотребления. В данной статье авторами предлагается алгоритм процедуры прогнозирования энергопотребления, основанный на применении нейронных сетей, с его последующей апробацией, используя реальные данные энергопотребления.

Для исследования суточной динамики энергопотребления были получены данные из журналов нагрузки реклоузеров, установленных в различных фидерах распределенной сети. С целью упрощения работы с Дневник науки | www.dnevnika.ru | СМИ ЭЛ № ФС 77-68405 ISSN 2541-8327

данными, была выполнена предварительная обработка журналов, заключающаяся в преобразовании данных в форму таблицы, содержащую столбцы с данными, датой и временем. Работа с таблицами данных сопряжена с анализом различных выборок, взятых из генеральной совокупности (журнал нагрузки реклоузера), следовательно, для корректной обработки представленных данных энергопотребления необходимо исключить из выборки выбросы (шумы). Ввиду необходимости точного определения паттернов (шаблонов) динамики энергопотребления будет применён медианный фильтр, практическая ценность которого состоит в замене аномальных значений сигнала, на значение медианы числовой последовательности (рис. 1).



— Отфильтрованные данные — Исходные данные

Рис. 1 Пример применения медианного фильтра

Последующая обработка отфильтрованного сигнала, а также выявление характерных паттернов динамики энергопотребления напрямую связаны с применением технологии машинного зрения, основанной на искусственной нейронной сети глубокого обучения. Данная технология является упрощённым механизмом обработки данных и решения задач, позаимствованного у биологических нейронных сетей и показывает довольно неплохие результаты в распознавании графических изображений. Основные преимущества искусственных нейронных сетей заключаются в параллельной обработке информации и способности обучаться, то есть — создавать

обобщение. Эти преимущества позволяют решать масштабируемые (сложные) задачи, которые до этого считались трудно разрешимыми

В настоящее время, одним из лучших инструментов, использующихся для глубокого обучения, является фреймворк TensorFlow [6]. Данный инструмент является разработкой компании Google и имеет открытый код, что позволяет гибко встраивать его для решения различных задач. По своему функционалу TensorFlow является довольно мощным инструментом с большим количеством возможностей, однако работа с ним сопровождается рядом сложностей [7]. Ввиду этого, для работы с данным инструментом была применена библиотека Keras. Эта библиотека является надстройкой над фреймворком TensorFlow и позволяет существенно упростить работу, связанную с формированием нейронной сети.

Для решения задач классификации графиков энергопотребления была использована нейронная сеть, состоящая из двух свёрточных и одного полносвязного слоя (рис. 2).

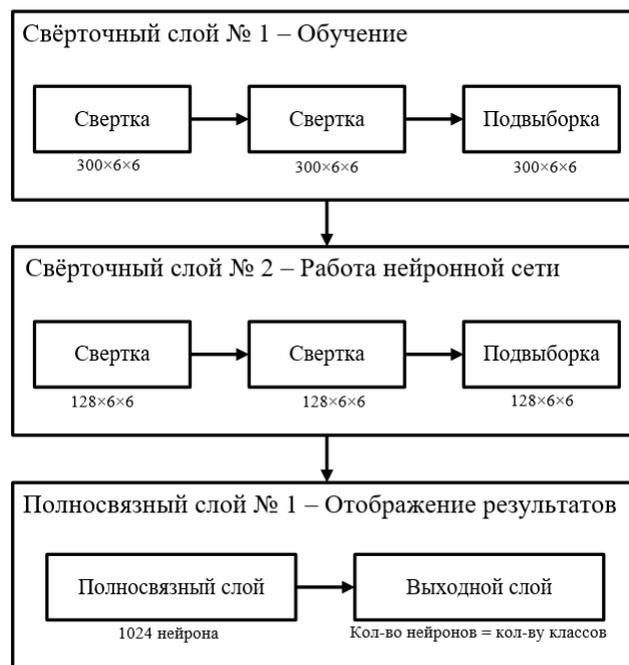


Рис. 2 Упрощённая структура искусственной нейронной сети

Свёрточный слой № 1 и № 2 состоят из двух свёрток и одной

Дневник науки | www.dnevnika.ru | СМИ ЭЛ № ФС 77-68405 ISSN 2541-8327

подвыборки, которые необходимы для обучения сети процессу выделения характерных признаков паттернов энергопотребления на тестовых данных. Также, в данных слоях, происходит работа нейронной сети по распределению входных данных (графиков динамики энергопотребления) по определённым классам. Слои включают по 300 и 128 карт признаков соответственно размером 6×6 , то есть каждый нейрон подключен к части изображения, размером 6×6 пиксел.

Полносвязный слой № 1 необходим для подведения итогов работы двух предшествующих слоёв, то есть обработки входных весов связей на основании которых будет принято решение о принадлежности паттерна к определённому классу. Он состоит из полносвязного слоя, включающего 1024 нейрона и выходного слоя, количество нейронов в котором определяется количеством классов графиков энергопотребления.

Процесс обучения нейронной сети представлен в виде функциональной блок-схемы (рис. 3). Программная реализация модуля была написана на языке программирования Python с использованием библиотек TensorFlow, Keras, NumPy и других.

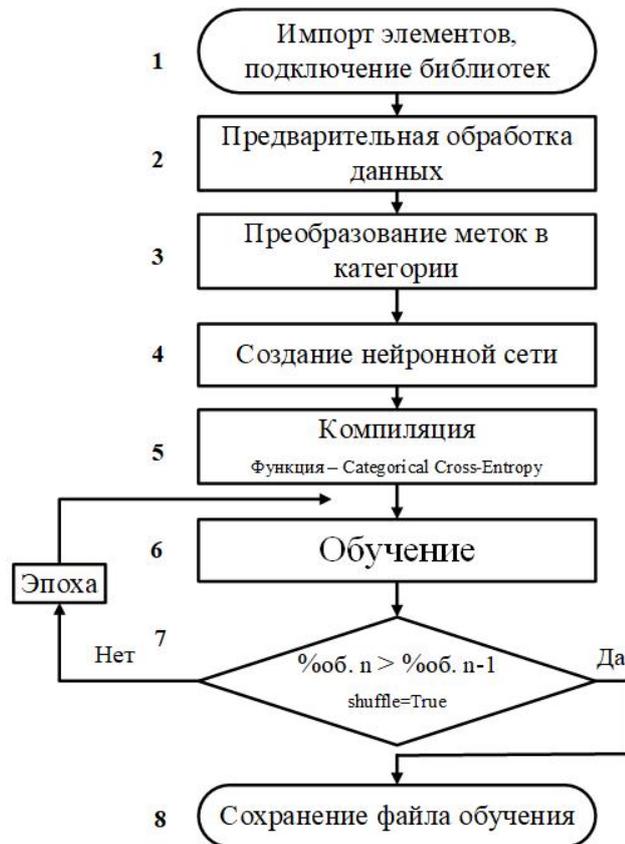


Рис. 3 Функциональная блок-схема свёрточного слоя № 1

Работа выше представленной функциональной блок-схемы описывается следующим алгоритмом:

Шаг 1: Импорт элементов: графики обучающей и тестовой выборок, отдельные модули из библиотек, необходимых для корректной работы нейронной сети. Подключение библиотек: TensorFlow, Keras, NumPy. Библиотека Keras необходима для регулирования процесса обучения нейронной сети. Библиотека NumPy используется для работы с большими массивами данных и матрицами.

Шаг 2: Предварительная обработка данных. Приведение всех изображений графиков обучающей выборки к одному размеру и формату, нормализация пикселей (привести к одной цветовой гамме).

Шаг 3: Преобразование меток в категории. Создание переменных (уникальных цифровых кодов, «понятных» для нейронной сети) и

присвоение им меток с последующим преобразованием в категории, ввиду взаимоисключаемости данных меток.

Шаг 4: Создание нейронной сети. Создание нейронной сети прямого распространения (Sequential) путём последовательного добавления необходимых слоёв, а также задания их размера.

Шаг 5: Компиляция. Проверка нейронной сети на ошибки (используется функция Categorical Cross-Entropy).

Шаг 6: Обучение. Запуск скрипта, активирующего процесс обучения. Определение оптимального количества эпох (полных циклов обучения), требуемых для корректного процесса обучения. В ходе процесса обучения важно не дать нейронной сети переобучиться, что приведёт к резкому падению способности сети корректно обрабатывать последующие входные данные. Пример некоторых графиков и обучающей выборки представлен на рис. 4. Для обучения нейронной сети использовались 120 графиков суточного энергопотребления для каждого фидера.

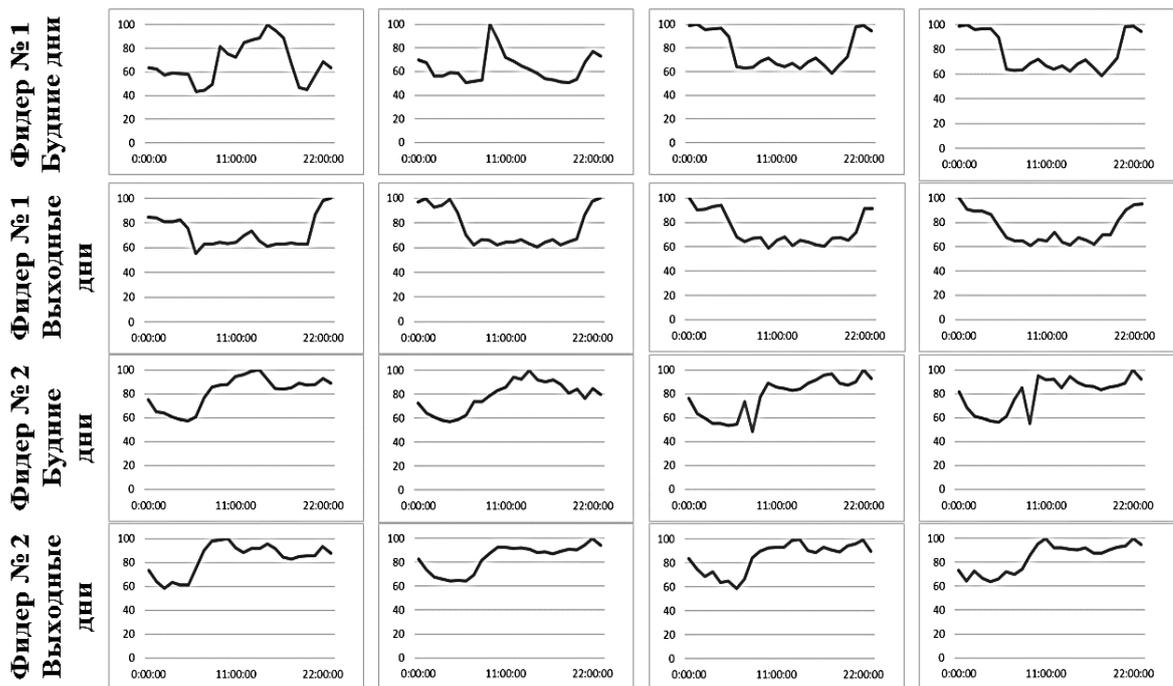


Рис. 4 Пример графиков обучающей выборки

Шаг 7: Сравнение доли верных ответов тестовой выборки предыдущей эпохи с последующей. Для корректной процедуры сравнения необходимо
Дневник науки | www.dnevnika.ru | СМИ ЭЛ № ФС 77-68405 ISSN 2541-8327

установить `shuffle=True` для перемешивания входных данных. Перемешивание позволит процессу обучения сети не зависеть от порядка входных данных.

Шаг «Нет»: В случае большего процента верных ответов тестовой выборки последующей эпохи, необходимо добавить в цикл ещё одну эпоху для до обучения нейронной сети.

Шаг «Да»: Преобладание верных ответов в тестовой выборке предыдущей эпохи показывает, что сеть начала переобучаться и процесс обучения необходимо заканчивать. Выбрано оптимальное количество эпох.

Шаг 8: Сохранение файла обучения. Производится сохранение файла обучения с оптимальным количеством эпох, необходимого для дальнейшей работы.

Процесс работы свёрточного слоя № 2 можно представить в виде функциональной блок-схемы (рис. 5).

Шаг 1: Внесение графиков энергопотребления в рабочую среду нейронной сети. Необходимо перенести выборку из графиков динамики энергопотребления в рабочую среду нейронной сети.

Шаг 2: Подключение библиотек, основные: TensorFlow, Numpy, вспомогательные: OS, Time, Sys, Argparse. OS и Sys необходимы для работы с операционной системой компьютера, а также для доступа к некоторым функциям и переменным интерпретатора Python, Time – для работы с временем, Argparse – для разбиения и обработки аргументов командной строки.

Шаг 3: Проверка наличия файла с перечнем вносимых файлов. Для дальнейшей корректной работы нейронной сети необходимо проверить наличие временного файла с перечнем вносимых файлов с графиками динамики энергопотребления.

Шаг «Да»: Удаление файла. В случае обнаружения вышеуказанного файла его необходимо удалить.

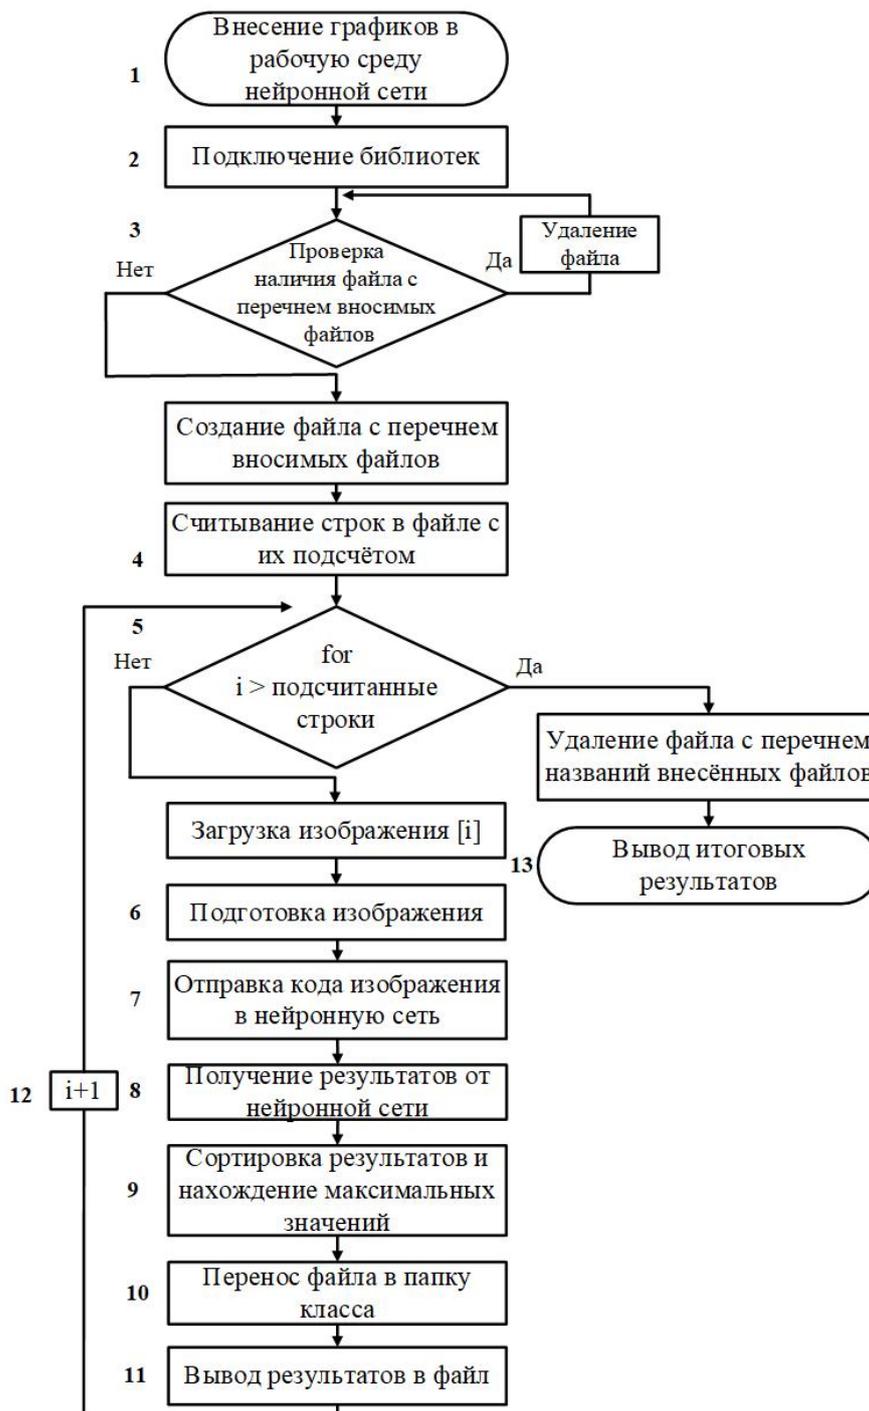


Рис. 5 Функциональная блок-схема свёрточного слоя № 1

Шаг «Нет»: Создание файла с перечнем вносимых файлов. В случае неуспешной проверки, необходимо создать временный файл с перечнем названий и расширений вносимых данных.

Шаг 4: Считывание строк в файле с их подсчётом. Подсчёт строк с названиями и расширениями всех внесённых файлов для определения

количества итераций.

Шаг 5: «for i > подсчитанные строки». Проверка, превысил ли счётчик количество ранее подсчитанных строк.

Шаг «Нет»: Загрузка изображения [i]. Загрузка следующего в перечне файла.

Шаг 6: Подготовка файла. Приведение всех изображений графиков к одному размеру, формату, нормализация пикселей. Оцифровка в пригодный для распознавания нейронной сетью вид.

Шаг 7: Отправка кода изображения в нейронную сеть. Осуществляется отправка преобразованного кода изображения в нейронную сеть.

Шаг 8: Получение результатов от нейронной сети. Определение нейронной сетью на сколько процентов внесённое изображение соответствует определённому классу.

Шаг 9: Сортировка результатов и нахождение максимальных значений. Сортировка полученных результатов, записанных в виде процента соответствия определённому классу, нахождение максимального значения соответствия.

Шаг 10: Перенос файла в папку класса. Перенос i-го файла с изображением в папку, предназначенную для определённого класса.

Шаг 11: Вывод результатов в файл. Дописывание результата классификации в итоговый файл.

Шаг 12: «i+1». Рассмотрение следующего в перечне файла с изображением.

Шаг «Да»: Удаление файла с перечнем названий внесённых файлов. По окончании работы нейронной сети, необходимо удалить временный файл с перечнем всех внесённых файлов.

Шаг 13: Вывод итоговых результатов. Вывод результатов классификации входных данных (графиков динамики энергопотребления) по определённым классам.

Заключение

Результаты проведенных вычислительных экспериментов, выполненных по предложенной в статье методике, показывают, что использование нейронных сетей глубокого обучения позволяют с довольно высокой точностью выявлять зависимости в графиках энергопотребления. Точность классификации графиков нагрузки, полученных на тестовой выборке, состоящей из 60 изображений, характеризующих суточную нагрузку различных потребителей 2-х фидеров, составила 95 %. Таким образом, на основании предложенной в статье методики, используя журналы нагрузки, можно производить прогнозирование энергопотребления потребителей распределенной сети с довольно высокой точностью.

Также необходимо отметить, что анализ результатов классификации графиков нагрузки потребителей показывает, что ошибочные результаты были получены только при определении будних и выходных дней в рамках одного фидера. Однако, при классификации самого фидера, не возникло ни одной ошибки. Это обстоятельство позволяет предположить, что точность классификации может быть увеличена при более тщательной сепарации обучающих данных, характеризующих выходной и будний день, учитывая, к примеру, праздничные дни, приходящиеся на будний день.

Исследование выполнено при финансовой поддержке РФФИ и Правительства Севастополя в рамках научного проекта № 20-47-920006.

Библиографический список:

1. The UNECE–ITU Smart Sustainable Cities Indicators // Economic and Social Council United Nations URL: http://www.unecce.org/fileadmin/DAM/hlm/documents/2015/ECE_HBP_2015_4.en.pdf
2. Hara M. et al. New key performance indicators for a smart sustainable city // Sustainability. 2016. V. 8, No.3. pp. 206.
3. Bibri S. E. A foundational framework for smart sustainable city
Дневник науки | www.dnevnika.ru | СМЭЛ № ФС 77-68405 ISSN 2541-8327

development: Theoretical, disciplinary, and discursive dimensions and their synergies // Sustainable Cities Soc. 2018. V. 38. pp. 758-794.

4. Чебоксаров В.В., Кузнецов П.Н. Пути решения проблемы неустойчивости энерговыработки установок возобновляемой энергетики / В.В. Чебоксаров, П.Н. Кузнецов //Дневник науки. - 2019. - № 4 (28). – С. 60-66.

5. Kuznetsov, P.N., Lyamina, N.V. & Yuferev, L.Y. A Device for Remote Monitoring of Solar Power Plant Parameters. Appl. Sol. Energy 55, 247–251 (2019). <https://doi.org/10.3103/S0003701X19040078>

6. Abadi, M. TensorFlow: A system for large-scale machine learning / M. Abadi, P. Barham, J. Chen and etc. // 2016 г. — № 12th USENIX Symposium on Operating Systems Design and Implementation (OSDI 16) — С. 265-283

7. Eyre H.J., Lange D.P., Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems. 2nd ed. O'Reilly, 2019. 817 p.

8. Betancourt R., Chen S. Pandas Library. In: Python for SAS Users. Apress, Berkeley, CA, 2019. 452 p. DOI https://doi.org/10.1007/978-1-4842-001-3_3

Оригинальность 95%