



Нейронная сеть для прогнозирования нагрузок энергопотребления сортировочного узла



Владимир ГРИДИН



Виктор ДОЕНИН



Владимир ПАНИЩЕВ



Игорь БЫСОВ

Гридин Владимир Николаевич – Центр информационных технологий в проектировании Российской академии наук, Москва, Россия.

Доенин Виктор Васильевич – Центр информационных технологий в проектировании Российской академии наук, Москва, Россия.

Панищев Владимир Славиевич – Центр информационных технологий в проектировании Российской академии наук, Москва, Россия.

Бысов Игорь Дмитриевич – Юго-Западный государственный университет, Курск, Россия.*

Предложено описание многослойной нейронной сети, предназначенной для предсказания среднесуточного потребления электроэнергии сортировочным узлом железной дороги. Для решения данной задачи была построена модель на основе многослойного персептрона, использующая 22 входа, n -ое количество скрытых слоёв и один выход. Количество скрытых слоёв в нейросети и нейронов в них было подобрано экспериментально. Проведён сравнительный подбор функций активации и методов обучения, позволяющий при всех прочих параметрах достичь минимальной средней относительной ошибки.

Выделено два вида нагрузок, соответствующих праздничным (нерабочим) и рабочим дням, что потребовало введения одного дополнительного входного узла с двоичным кодированием и двух узлов для кодирования

времени года, что обусловлено определённой повторяемостью характеризующих выборок предсказания нагрузок потребления энергии узла сортировочной станции в зависимости от типа дня и времени года. Важнейшим фактором также являлся учёт зависимости прогноза от значений нагрузки в предыдущие дни и годы (динамические зависимости), и в данной нейросети учтено среднесуточное потребление энергии по данным четырёх предыдущих дней текущего периода и четырёх предыдущих дней за последние три года.

В итоге, с учётом всех факторов и экспериментально подобранных параметров нейросети, минимальная получившаяся погрешность MAPE составляет порядка 1,4%, что, в сравнении с двумя сторонними решениями для данной задачи, показывает преимущество разработанной нейросети.

Ключевые слова: многослойная нейронная сеть, прогнозирование, персептрон, электроэнергия, предсказание нагрузок, сортировочный узел.

*Информация об авторах:

Гридин Владимир Николаевич – доктор технических наук, профессор, научный руководитель Центра информационных технологий в проектировании Российской академии наук (ЦИТП РАН), Москва, Россия, info@ditc.ras.ru.

Доенин Виктор Васильевич – доктор технических наук, главный научный сотрудник Центра информационных технологий в проектировании Российской академии наук (ЦИТП РАН), профессор Российского университета транспорта, Москва, Россия, info@ditc.ras.ru.

Панищев Владимир Славиевич – кандидат технических наук, старший научный сотрудник Центра информационных технологий в проектировании Российской академии наук (ЦИТП РАН), Москва, Россия, gskunk@yandex.ru.

Бысов Игорь Дмитриевич – студент магистратуры Юго-Западного государственного университета (ЮЗГУ), Курск, Россия, bysov93@mail.ru.

Статья поступила в редакцию 27.02.2019, принята к публикации 30.05.2019.

For the English text of the article please see p. 11.

Работа выполнена при поддержке РФФИ, проект 17–20–01133 офи_м_РЖД.

Эффективное энергопроизводство и прогнозирование энергопотребления являются важными проблемами современности. Конечной целью энергосбережения является сокращение затрат организации на оплату энергоресурсов, что обуславливает необходимость использования средств исследования текущего потребления и его прогнозирования. В рамках сортировочной станции данная информация является одной из составляющих интеллектуальной подсистемы анализа и прогнозирования загрузки.

В качестве модели прогнозирования на малых интервалах достаточно использовать полиномиальные разложения [1, с. 42], но на длительном временном интервале приведённые модели непригодны из-за невозможности разложения данных по базису небольшой размерности. Для достижения достаточной точности прогноза в этом случае применимы авторегрессионные методы [2, 3].

Но все перечисленные выше методы обладают одним существенным недостатком – их применение требует обязательного участия специалиста. Поэтому необходимо использовать более выгодный алгоритм, минимизирующий человеческий фактор при построении прогноза. В качестве такого алгоритма могут выступать искусственные нейронные сети, с успехом

использующиеся для решения задачи предсказания [4, с. 17].

Целью работы является построение модели искусственной нейронной сети на основе многослойного персептрона для задачи прогнозирования энергопотребления сортировочного узла.

Авторы использовали математические методы и инструменты информатики и программирования, частные методы построения искусственных нейронных сетей, многослойный персептрон с различными функциями активации (сигмоидальная функция, выпрямленная линейная функция активации, функция гиперболический тангенс), методы обучения (L-BFGS, стохастический оптимизационный алгоритм ADAM [5]).

МОДЕЛЬ НЕЙРОСЕТИ

Для предсказания нагрузки энергетического потребления выбран массив данных энергопотребления за 14 лет, из которого формируется структура данных из шести столбцов, где столбец 0 – среднесуточное потребление, 1 – год, 2 – номер дня в году, 3 – выходной день (0) или рабочий (1), 4 и 5 – двоичное кодирование времени года – зима (11), весна (01), лето (00), осень (10). Далее формируется массив обучающей выборки за 12 лет как зависимости от 4 предшествующих дней текущего периода и 4 предшествующих дней 3 предшествую-

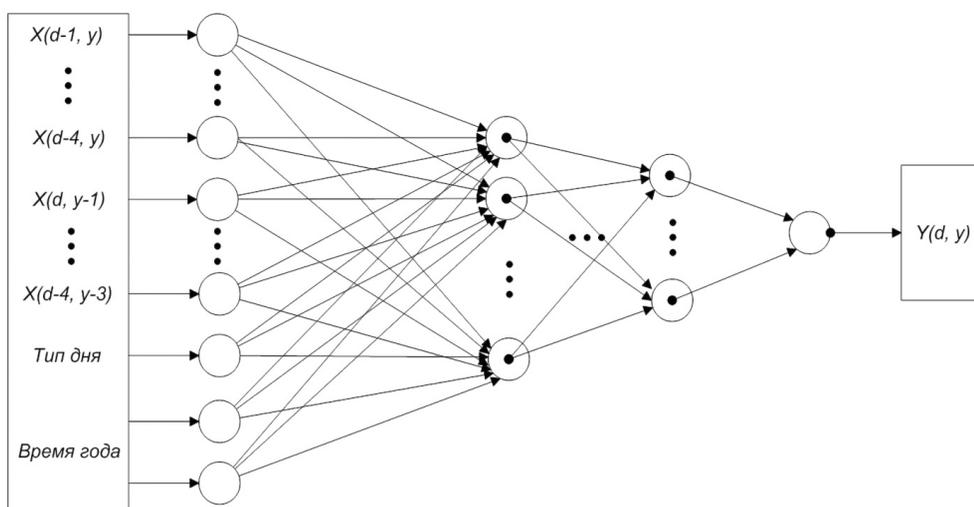
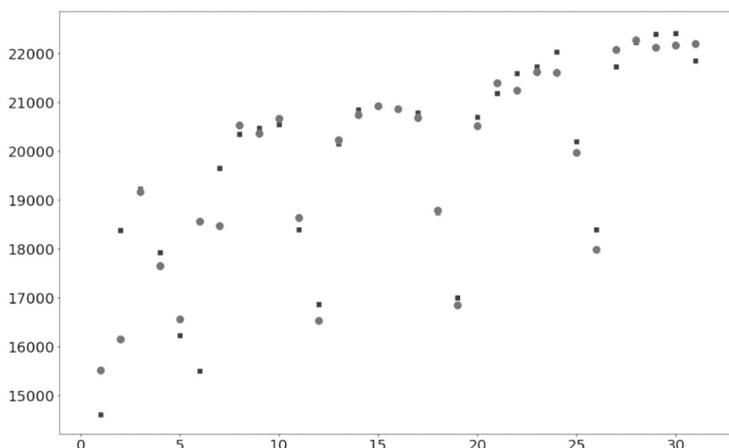


Рис. 1. Структура персептронной нейросети для прогнозирования энергопотребления.



Рис. 2. Графическое изображение работы нейросети. Выпрямленная линейная функция активации, метод обучения – «L-BFGS».



ших лет, от типа дня и от сезона, кроме того, учитываются високосные года. Таким образом, массив имеет 23 столбца, где столбец 0 – зависимая переменная Y , и 22 столбца – независимые переменные X . Последними шагами являются построение нейросети в соответствии с возможным подбором параметров, изложенным в [6], её обучение и прогнозирование энергопотребления на два года. Выходные, учитываемые в данной модели нейросети, брались два раза – праздники РФ и даты, празднуемые в Польше, для сравнения с аналогом, предсказывающим нагрузки Польской электроэнергетической системы: 1 января, 6 января, 1 мая, 3 мая, 15 августа, 1 ноября, 11 ноября, 25–26 декабря – это необходимо учитывать для достижения максимальной точности предсказания. Наиболее полное исследование было проведено по данным 2002–2015 годов с формированием обучающей выборки 2005–2013 гг., прогнозом на 2014–2015 гг. с его последующей сверкой с фактическими данными. Построение нейронной сети проводилось на языке «Python» [7–9]. На рисунке 1 изображена структура разработанной модели нейросети.

ПОДБОР ПАРАМЕТРОВ НЕЙРОСЕТИ

Для достижения минимальной возможной ошибки прогнозирования в разработанной модели многослойного персептрона проводился подбор оптимальных для данной задачи функций активации и методов обучения. Были рассмотрены следующие параметры нейросети:

1. Сигмоидальная функция активации – функция, принимающая произволь-

ное вещественное число на входе и дающая на выходе вещественное число в интервале от 0 до 1, выражается формулой: $\sigma(x) = 1 / (1 + e^{-x})$. В результате работы сигмоиды большие положительные числа превращаются в единицу, а большие отрицательные числа (по модулю) – в ноль.

2. Выпрямленная линейная функция активации (rectified linear unit, ReLU) выражается формулой: $\sigma(x) = \max(0, x)$. Её производная принимает только два значения – 0 и 1, что исключает затухание или разрастание градиентов, кроме того использование выпрямленной линейной функции приводит к прореживанию весов, однако она сильно нуждается в выборе правильной скорости обучения.

3. Функция активации гиперболический тангенс (tanh) получает на вход вещественное произвольное число и даёт на выходе вещественное число в интервале от -1 до 1, имеет возможность насыщения, так же как и сигмоидальная функция, но выход гиперболического тангенса центрирован относительно нуля.

4. Метод обучения «L-BFGS» – модификация алгоритма Бройдена–Флетчера–Гольдфарба–Шанно, предназначенная для решения нелинейных задач с большим количеством неизвестных и основанная на последовательном построении и уточнении квадратичной модели функции. «L-BFGS» запоминает последние значения градиента/функции и использует их для совершения шага по методу Ньютона и построения положительно определённой аппроксимации гессиана.

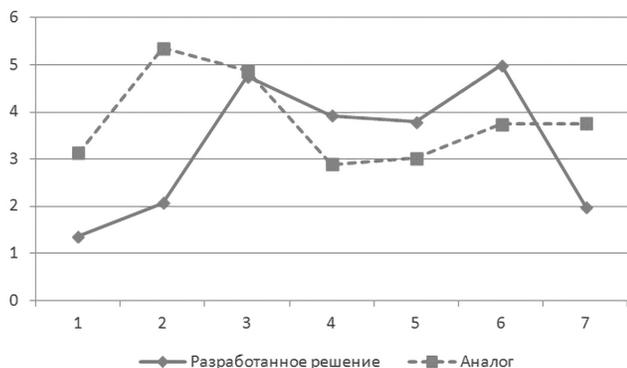


Рис. 3. Сравнительный график результатов прогнозирования на неделю разработанной нейросети и модели, описанной в [10, с. 114].

Таблица 1
Сравнительные данные погрешности MAPE для недельного прогноза

Недельный период прогнозирования	Погрешность MAPE среднесуточной нагрузки разработанной нейросети (%)	Погрешность MAPE модели, описанной в [10, с. 114] (%)
Понедельник	1.36	3.13
Вторник	2.07	5.36
Среда	4.75	4.87
Четверг	3.92	2.89
Пятница	3.79	3.02
Суббота	5.00	3.74
Воскресение	1.99	3.76

Таблица 2
Сравнительные данные погрешности MAPE для шестилетнего периода прогнозирования

Шестилетний период прогнозирования	Погрешность MAPE среднесуточной нагрузки разработанной нейросети (%)	Погрешность MAPE модели, описанной в [11, с. 128] (%)
1	1.24	1.2
2	1.28	1.3
3	1.21	1.25
4	1.31	1.32
5	1.26	1.34
6	1.35	1.36

5. Метод обучения адаптивного момента (adaptive moment estimation, Adam) – стохастический оптимизационный алгоритм, сочетающий в себе метод слабого обновления весов для типичных признаков и метод накопления движения. «Adam» является простым в реализации и эффективным вычислительно алгоритмом, имеющим в то же время мало требований к памяти, инвариантным к диагональному масштабированию градиентов и, таким образом, хорошо подходит для больших задач с точки зрения данных и/или параметров.

Используя описанные выше методы обучения и функции активации, проведён экспериментальный подбор оптимальных параметров для разрабатываемой модели нейросети:

1. Выпрямленная линейная функция активации, метод обучения – «L-BFGS» (см. рис. 2). При использовании одного скрытого слоя с 35 нейронами средняя относительная ошибка составляет 1,8 %, максимальная относительная ошибка – 29,4 %. При использовании в нейросети

пяти скрытых слоёв с количеством нейронов в каждом от 20 до 30 средняя относительная ошибка уменьшается до 1,4 %, а максимальная относительная ошибка – до 28,2 %. Дальнейшее увеличение количества скрытых слоёв и нейронов не приносит увеличения качества прогнозирования. При использовании метода обучения адаптивного момента средняя относительная ошибка увеличивается до 2,7 %.

2. Функция активации – гиперболический тангенс, метод обучения – адаптивная инерция, использовался один скрытый слой с 35 нейронами, проведена нормализация данных. Средняя относительная ошибка составила 3,7 %, максимальная относительная ошибка – 39,8 %. При увеличении количества слоёв ошибка увеличивается. Использование сигмоидальной функции активации с методом обучения адаптивного момента даёт повышение средней относительной ошибки до 4 % и максимальной до 41 %.

В таблицах 1 и 2, на рис. 3 и 4 представлен сравнительный анализ ошибок MAPE



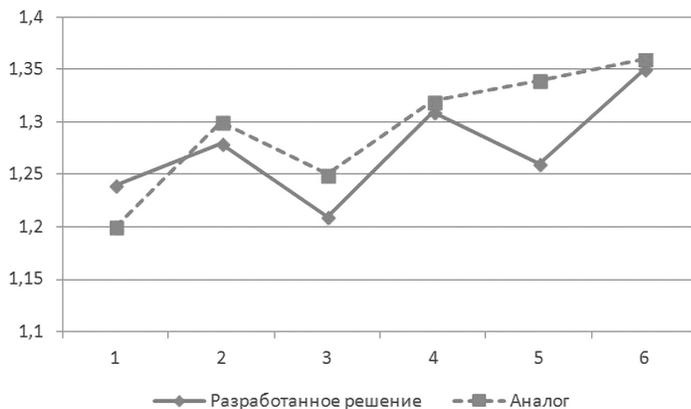


Рис. 4. Сравнительный график результатов прогнозирования на шесть лет разработанной нейросети и модели, описанной в [11 с. 128].

для разработанной перцептронной нейросети и аналогов.

Из таблицы 1 видно, что для отдельно взятой недели разработанная нейросеть предсказывает среднесуточное энергопотребление в целом лучше, чем её аналог.

Из таблицы 2 видно, что наибольшая погрешность MAPE для разработанной нейросети в течение шести лет не превышала 1,4 %.

ЗАКЛЮЧЕНИЕ

Была разработана модель нейронной сети на основе многослойного перцептрона и проведён экспериментальный подбор параметров нейросети, что позволило обеспечить прогнозирование энергопотребления со средней относительной ошибкой в 1,4 %. Таким образом, экспериментальные данные подтвердили возможность использования данной нейросети для прогнозирования нагрузок энергопотребления сортировочного узла при условии учёта плавающего графика праздничных дней для компенсации высоких значений ошибок прогнозирования.

В ходе дальнейших разработок на основе полученных результатов данная модель может быть также использована для прогнозирования энергопотребления в масштабах железнодорожной станции, транспортно-логистического узла.

ЛИТЕРАТУРА

1. Ахметьянов Р. Р., Делегодина Л. А., Копылова Н. П. и др. Задачи прогнозирования энергопотребления в интегрированной АСКУЭ Новосибирского научного центра // Энергосбережение. — 2007. — № 1. — С. 42–47.

2. Ахметьянов Р. Р., Делегодина Л. А., Копылова Н. П. и др. Мультипликативная модель сезонного энергопотребления предприятий // Автотметрия. — 2008. — № 3. — С. 106–118.

3. Ахметьянов Р. Р., Делегодина Л. А., Копылова Н. П. и др. Использование нестандартных сезонных моделей авторегрессии и проинтегрированного скользящего среднего в задачах ресурсосбережения // Автотметрия. — 2008. — № 4. — С. 28–41.

4. Бысов И. Д., Панищев В. С. Использование нейронной сети для прогнозирования нагрузок энергетического потребления предприятия // Тенденции развития науки и образования. — 2017. — № 33–1. — С. 17–18.

5. Kingma, D. P., Ba, J. Adam: A Method for Stochastic Optimization. — Cornell University Library. — 2014. [Электронный ресурс]: <https://arxiv.org/pdf/1412.6980.pdf>. Доступ 27.02.2019.

6. Гридин В. Н., Солодовников В. И., Карнаков В. В. Выбор начальных значений и оптимизация параметров нейронной сети // Новые информационные технологии в автоматизированных системах. — 2016. — № 19. — С. 270–273.

7. Мюллер А., Гвидо С. Введение в машинное обучение с помощью Python / Пер. с англ. — М.: Вильямс, 2017. — 480 с.

8. Рашка С. Python и машинное обучение / Пер. с англ. — М.: ДМК Пресс, 2017. — 418 с.

9. Маккинни У. Python и анализ данных / Пер. с англ. — М.: ДМК Пресс, 2015. — 482 с.

10. Соломахо К. Л. Применение метода главных компонент для прогнозирования объёмов электропотребления энергосбытового предприятия / Дис... канд. техн. наук. Южно-Уральский государственный университет, Челябинск, 2015 [Электронный ресурс]: https://www.susu.ru/sites/default/files/dissertation/03_text_diss_5.pdf. Доступ 27.02.2019.

11. Осовский С. Нейронные сети для обработки информации. — М.: Финансы и статистика, 2002. — 344 с.

12. Гридин В. Н., Доенин В. В., Солодовников В. И., Панищев В. С., Труфанов М. И. К вопросу построения интеллектуальной подсистемы анализа и прогнозирования работы сортировочного узла // Информационные технологии и вычислительные системы. — 2017. — № 4. — С. 95–103.

13. Гридин В. Н., Доенин В. В., Панищев В. С. О построении интеллектуальной подсистемы анализа параметров сортировочного узла // Мир транспорта. — 2017. — № 4. — С. 6–19. ●