

# ПРИМЕНЕНИЕ АДАПТИВНОГО АНСАМБЛЕВОГО НЕЙРОСЕТЕВОГО МЕТОДА ДЛЯ КРАТКОСРОЧНОГО ПРОГНОЗИРОВАНИЯ ЭЛЕКТРОПОТРЕБЛЕНИЯ ЭЛЕКТРОТЕХНИЧЕСКОГО КОМПЛЕКСА РАЙОННЫХ ЭЛЕКТРИЧЕСКИХ СЕТЕЙ

Статья посвящена проблеме повышения точности краткосрочного прогнозирования потребления электроэнергии электротехнического комплекса районных электрических сетей с помощью инструментов глубокого машинного обучения. Исследована эффективность применения адаптивного алгоритма обучения глубоких нейронных сетей при краткосрочном прогнозировании электропотребления данного электротехнического комплекса. Рассмотрены вопросы, связанные с применением сверточных и рекуррентных нейронных сетей для решения задачи прогнозирования электрических нагрузок. Проведен сравнительный анализ точности краткосрочного прогноза потребления электроэнергии разработанного ансамблевого метода с точностью прогноза, полученного с помощью нейронных сетей стандартной архитектуры.

**Ключевые слова:** районные электрические сети, прогнозирование потребления электроэнергии, искусственная нейронная сеть, алгоритм обучения, сети свертки, рекуррентные нейросети.

**Введение.** Районные электрические сети представляют собой сложный электротехнический комплекс, включающий электросетевое оборудование напряжением 35 кВ и ниже, а также различные категории потребителей электроэнергии. Как было выяснено в работе [1], почасовое электропотребление электротехнического комплекса районных электрических сетей (ЭТК РЭС) описывается сложной нелинейной функциональной зависимостью, зависящей от множества факторов. Вследствие этого краткосрочное прогнозирование почасового электропотребления (short-term load forecasting — STLF) ЭТК РЭС относится к слабоформализуемым задачам. Данное обстоятельство осложняется тем фактом, что часть факторов имеют недетерминированный характер, величину которых невозможно точно определить заранее. К числу таких факторов можно отнести прогноз метеорологических условий, плановые и аварийные отключения электросетевого оборудования и т.д. В условиях неопределенности традиционные методы математической статистики или имитационного моделирования не позволяют строить адекватные модели объектов [2].

В настоящее время наблюдается стремительное развитие таких областей информационных технологий, как искусственный интеллект, систе-

мы обработки больших объемов данных (Big Data) и глубокое машинное обучение. Рассмотренные информационные технологии являются высокоэффективным инструментом для решения широкого перечня задач, которые относятся к слабоформализуемым или неформализуемым [3]. За последние несколько десятилетий ученые разработали множество математических моделей и методов повышения точности STLF, которые можно разделить на методы, основанные на математической статистике, методы искусственного интеллекта и гибридные методы [4, 5]. И. И. Надтока и Б. М. Аль Зихери разработали модель краткосрочного прогнозирования потребления электроэнергии в регионе, основанную на методе опорных векторов и роя частиц [6]; К. В. Соломахо разработала модель прогнозирования потребления электроэнергии энергосбытовой компании на основе метода анализа главных компонент [7]; Грицай А. С. разработал гибридную модель краткосрочного прогнозирования потребления электроэнергии на основе формирования обучающей выборки с применением функции конкурентного сходства и трехслойного перцептрона [8]; Rahmana A, Sri Kumar V. разработали модель прогнозирования электропотребления жилых и коммерческих зданий на основе глубокой рекуррентной нейронной сети [9]. Несмотря на большое количество математиче-

ских моделей и методов прогнозирования электропотребления ни один из них не может быть назван универсальным. Существующие математические модели разрабатывались для прогнозирования электропотребления электроэнергетических систем или конечных потребителей электроэнергии, таких как здания и промышленные предприятия. В исследовании [10] было выяснено, что математическая модель почасового электропотребления ЭТК РЭС должна учитывать помимо стандартных факторов времени, температуры наружного воздуха и освещенности следующие факторы:

— отключения на электрических сетях напряжением 6–220 кВ;

— производственный режим потребителей электроэнергии с присоединенной мощностью свыше 670 кВт;

— наличие центрального отопления и горячего (холодного) водоснабжения в отдельных населенных пунктах;

— инерционности изменения режима электропотребления ЭТК РЭС в связи с перепадами температуры воздуха.

В связи с учетом вышеперечисленных факторов при краткосрочном прогнозировании потребления электроэнергии ЭТК РЭС необходимо рассмотреть вопросы выбора оптимальной конфигурации нейронной сети, которая позволяет достичь максимальной точности прогноза электропотребления. Вследствие увеличения размерности факторного пространства необходимо рассмотреть вопросы улучшения сходимости алгоритма обучения нейросетевых алгоритмов.

Также вышеперечисленные методы прогнозирования потребления электроэнергии основаны на устаревших методах машинного обучения, таких как метод опорных векторов, метод главных компонент, перцептроны различной конфигурации и т.п. В настоящее время при решении практических задач предпочтение отдают методам, основанным на глубоких сетях свертки, рекуррентных нейросетях, а также ансамблям, состоящим из нескольких параллельно работающих прогнозных алгоритмов, отклики которых комбинируются некоторым способом. Наиболее распространенным способом получения итогового выходного сигнала является блок усреднения по ансамблю. Композиционные методы классификации формируют набор различных моделей классификации для достижения лучшей точности, чем у каждой модели в отдельности [11].

Использование ансамблей нейронных сетей при STLF рассмотрено в [12, 13].

#### **Исследование эффективности применения адаптивных оптимизаторов функции энергии ошибки нейронных сетей при краткосрочном прогнозировании электропотребления ЭТК РЭС.**

Обучение современных глубоких искусственных нейронных сетей (ИНС), предназначенных для краткосрочного прогнозирования электропотребления, происходит на основании алгоритма обратного распространения ошибки. В процессе работы данного алгоритма происходит два прохода вычислений: прямой и обратный. Во время прямого прохода вычислений на вход нейросети подается вектор признаков. После прохождения сигнала через все слои нейросети формируется выходной сигнал, являющийся откликом нейронной сети на входные воздействия. При прямом проходе сигнала свободные параметры сети остаются неизменными.

Далее, во время обратного прохода, рассчитывается функция энергии ошибки по всем нейронам выходного слоя:

$$J(n) = \frac{1}{2C} \sum_{j \in C} e_j^2(n), \quad (1)$$

где  $J(n)$  — функция энергии ошибки на шаге обучения  $n$ ;  $C$  — множество нейронов выходного слоя;  $e_j^2$  — квадратичная ошибка нейрона  $j$ .

В данном случае имеется задача оптимизации, целевым параметром которой является функция стоимости. Наиболее успешным на сегодняшний день алгоритмом оптимизации сложных функций является алгоритм градиентного спуска (gradient descent algorithm). Если целевая функция дифференцируема по своим параметрам, то градиентный спуск является относительно эффективным методом оптимизации [14].

В случае использования алгоритма градиентного спуска для оптимизации функции стоимости  $J(n)$  данная функция представляется в виде функциональной зависимости синоптических весов нейронной сети  $J(w)$ . Для визуализации процесса обучения строится поверхность ошибки функции  $J(w)$  в пространстве свободных параметров нейронной сети. Основная идея алгоритма обратного распространения ошибки состоит в коррекции синоптического веса  $w_{ij}(n)$  на величину  $\Delta w_{ij}(n)$ , которая пропорциональна градиенту функции стоимости  $\frac{\partial J(n)}{\partial w_{ij}(n)}$ :

$$\begin{aligned} \nabla J(n) &= \frac{\partial J(n)}{\partial w_{ij}(n)} = \frac{\partial J(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ij}(n)} = \\ &= -e_j(n) \phi'_j(v_j(n)) y_i(n), \end{aligned} \quad (2)$$

где  $\nabla J(n)$  — градиент функции потерь на шаге обучения  $n$ ;  $w_{ij}(n)$  — вес синоптической связи между нейронами  $i$  и  $j$ ;  $e_j(n)$  — сигнал ошибки нейрона  $j$  на шаге обучения  $n$ ;  $y_j(n)$  — отклик нейрона  $j$  на шаге обучения  $n$ ;  $\partial v_j(n)$  — индуцированное локальное поле нейрона  $j$  на шаге обучения  $n$ ;  $\phi'_j$  — функция активации.

Коррекция, применяемая к синоптическому весу взаимодействия  $w_{ij}(n)$  определяется согласно дельта-правилу:

$$\Delta w_{ij}(n) = -\eta \frac{\partial J(n)}{\partial w_{ij}(n)} = \eta e_j(n) \phi'_j(v_j(n)) y_i(n), \quad (3)$$

где  $w_{ij}(n)$  — корректировка веса взаимодействия между нейронами  $i$  и  $j$  на шаге обучения  $n$ ;  $\eta$  — коэффициент, учитывающий скорость обучения сети.

Как мы видим из выражения (3), целью обучения нейронной сети является итеративная коррекция весов синоптических связей ИНС, с целью нахождения глобального минимума функции стоимости:

$$w_{ij}(n+1) = w_{ij}(n) + \Delta w_{ij}(n). \quad (4)$$

Стохастический градиентный спуск работает без проблем при оптимизации выпуклых целевых функций. Однако функция энергии ошибки многослойной нейронной сети в большинстве случаев будет являться невыпуклой функцией. То есть данная функция имеет множество локальных минимумов, плато и седловых точек, в окрестности которых градиент принимает нулевое или положительные

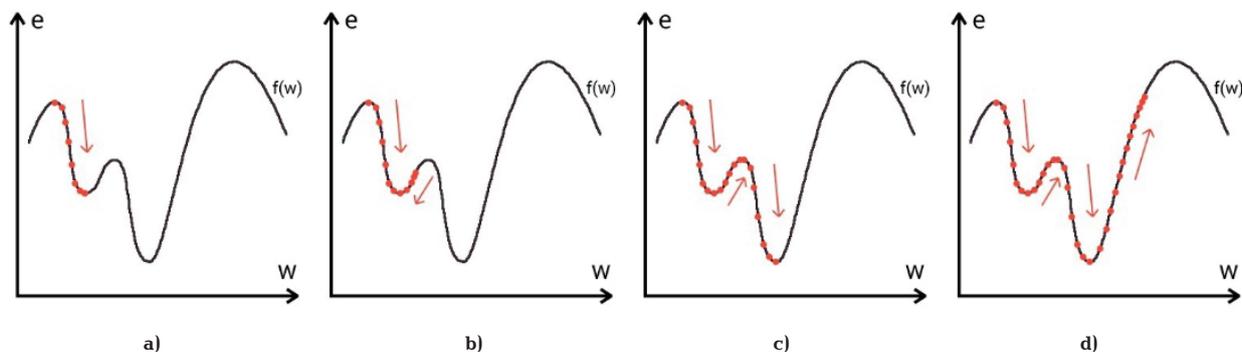


Рис. 1. Графики траектории движения рабочей точки алгоритма градиентного спуска по поверхности ошибки при различных значениях скорости обучения и момента инерции:  
 а) малое значение скорости обучения без момента инерции;  
 б) недостаточное значение скорости обучения и (или) момента инерции;  
 с) оптимальное значение скорости обучения и момента инерции;  
 д) слишком большое значение скорости обучения и (или) момента инерции

значения. Данное обстоятельство способствует замедлению сходимости алгоритма градиентного спуска в область глобального минимума поверхности ошибки. Для ускорения сходимости алгоритма обучения в выражение (3) добавляется член момента инерции:

$$\Delta w_{ij}(n) = \eta e_j(n) \phi'_j(v_j(n)) y_i(n) + \mu \Delta w_{ij}(n-1), \quad (5)$$

где  $\mu$  — параметр момента инерции;  $\Delta w_{ij}(n-1)$  — корректировка веса синоптической связи между нейронами  $i$  и  $j$  на итерации обучения  $n-1$ .

На рис. 1 представлены графики траектории движения рабочей точки алгоритма градиентного спуска по поверхности ошибки при различных значениях скорости обучения и момента инерции.

Накопление импульса, за счет применения параметра момента инерции, хоть и улучшает сходимость алгоритма обучения, но появляется дополнительный параметр нейросети, который невозможно определить в процессе обучения. Также применение момента не гарантирует достижения рабочей точки алгоритма глобального минимума на поверхности ошибки.

За последнее время ученые разработали множество успешных алгоритмов, минимизирующих количество параметров, требующих настройки в процессе обучения нейросети. Современные инструменты машинного обучения позволяют реализовать алгоритм обратного распространения ошибки с адаптивным, в процессе обучения, параметром скорости обучения, такие как ADAM и RMSProp [14].

Алгоритм RMSProp — это одна из модификаций алгоритма градиентного спуска (SGD), призванная улучшить сходимость SGD при невыпуклом характере функции потерь  $J$ . Идея алгоритма RMSProp заключается в коррекции параметра скорости обучения за счет накопления в знаменателе экспоненциально взвешенного скользящего среднего из квадратов градиентов функции потерь  $J$  (root mean square propagation — RMSprop):

$$E[g^2(n)] = \gamma E[g^2(n-1)] + (1-\gamma)g^2(n), \quad (6)$$

где  $E[g^2(n)]$  — экспоненциально взвешенное скользящее среднее из квадратов градиентов функции потерь  $J$  на шаге обучающего цикла  $n$ ;  $\gamma$  — сглажи-

вающая константа, значение которой по умолчанию равно 0,9;  $g(n) = \nabla J(n)$  — градиент функции потерь на шаге обучающего цикла  $n$ .

Тогда дельта-правило коррекции свободных параметров нейронной сети при использовании алгоритма RMSProp принимает вид:

$$w_{ij}(n+1) = w_{ij}(n) + \frac{\eta}{\sqrt{E[g^2(n)] + \varepsilon}} g(n), \quad (7)$$

где  $\varepsilon$  — константа небольшого значения, необходимая для исключения деления на ноль на начальных шагах обучающего цикла.

Алгоритм ADAM (adaptive momentum estimation — оценка адаптивных моментов) представляет собой комбинацию алгоритмов RMSProp и импульсного метода. Во-первых, рассчитывается первый момент, который представляет собой экспоненциальное скользящее среднее значений градиента функции потерь  $J$  и его скорректированное значение:

$$\begin{cases} m(n) = \beta_1 m(n-1) + (1-\beta_1)g(n), \\ \hat{m}(n) = \frac{m(n)}{1-\beta_1^n}, \end{cases} \quad (8)$$

где  $m(n)$  — экспоненциальное скользящее среднее значений градиента функции потерь  $J$ ;  $\beta_1$  — сглаживающая константа, значение которой по умолчанию равно 0,9;  $\hat{m}(n)$  — скорректированное значение экспоненциального скользящего среднего значений градиента функции потерь  $J$ .

Далее рассчитывается второй момент, который представляет из себя среднюю нецентрированную дисперсию функции потерь  $J$  и ее скорректированное значение:

$$\begin{cases} v(n) = \beta_2 v(n-1) + (1-\beta_2)g^2(n), \\ \hat{v}(n) = \frac{v(n)}{1-\beta_2^n}, \end{cases} \quad (9)$$

где  $v(n)$  — нецентрированная дисперсия функции потерь  $J$ ;  $\beta_2$  — сглаживающая константа, значение которой по умолчанию равно 0,999;  $\hat{v}(n)$  — скорректированное значение нецентрированной дисперсии функции потерь  $J$ .

Корректировка моментов  $m(n)$  и  $v(n)$  производится для искусственного увеличения данных параметров на начальных итерациях обучающего цикла.

Дельта-правило коррекции свободных параметров нейронной сети при использовании алгоритма ADAM принимает вид:

$$w_{ij}(n+1) = w_{ij}(n) + \frac{\eta}{\sqrt{\hat{v}(n) + \varepsilon}} \hat{m}(n). \quad (10)$$

Использование адаптивных оптимизаторов функции энергии ошибки способствует улучшению сходимости алгоритма обучения к окрестности глобального минимума вне зависимости от «ландшафта» поверхности ошибки. В данном случае рабочая точка алгоритма обучения более эффективно проходит локальные минимумы на поверхности ошибки. Алгоритмы ADAM и RMSProp хорошо зарекомендовали себя на практике, и окончательный выбор происходит на основании экспериментов с обучающей и проверочной выборками.

**Исследование влияния архитектуры и конфигурации нейронной сети на точность краткосрочного прогнозирования электропотребления ЭТК РЭС.** Алгоритмы обучения глубоких нейронных сетей, предназначенных для краткосрочного прогнозирования электропотребления ЭТК РЭС, включают оптимизацию в различных контекстах. Так, основная задача оптимизации в машинном обучении заключается в подборе параметров нейронной сети, значительно уменьшающих величину функции стоимости  $J(n)$ . Часть параметров, которые называются свободными параметрами нейронной сети, определяются в процессе обучения на обучающей выборке данных. Однако существует набор параметров, называемых гиперпараметрами, которые невозможно определить и уточнить в процессе обучения. К ним можно отнести:

- значение скорости обучения и момента инерции на каждой эпохе обучающего цикла;
- количество скрытых слоев сети;
- количество нейронов в каждом скрытом слое;
- функция активации нейронов скрытых и выходного слоев.

Адаптивные оптимизаторы функции потерь  $J$ , такие как алгоритм ADAM, позволяют поддерживать оптимальное значение параметров скорости обучения и момента инерции в процессе всего обучающего цикла. Однако, несмотря на то, что исследования по машинному обучению ведутся уже более 70-ти лет, до сих пор не разработано формализованных методов определения оптимальных значений гиперпараметров, связанных с архитектурой нейросетевой модели. Проектирование нейронной сети сводится к многочисленным экспериментам с обучающей и тестовой выборкой данных, в результате чего подбирается оптимальная конфигурация нейросетевой модели. Однако современные инструменты машинного обучения, такие как библиотека машинного обучения Keras, позволяют автоматизировать данный поиск на основании алгоритмов байесовской оптимизации и Hyperband. Для определения оптимальной конфигурации ИНС с помощью инструментов библиотеки глубокого машинного обучения Keras задается набор гиперпараметров, оптимальные значения которых необходимо найти, границы изменения каждого из гиперпараметров, а также дискретность (шаг) изменения данной величины в процессе поиска. После обучения и тестиро-

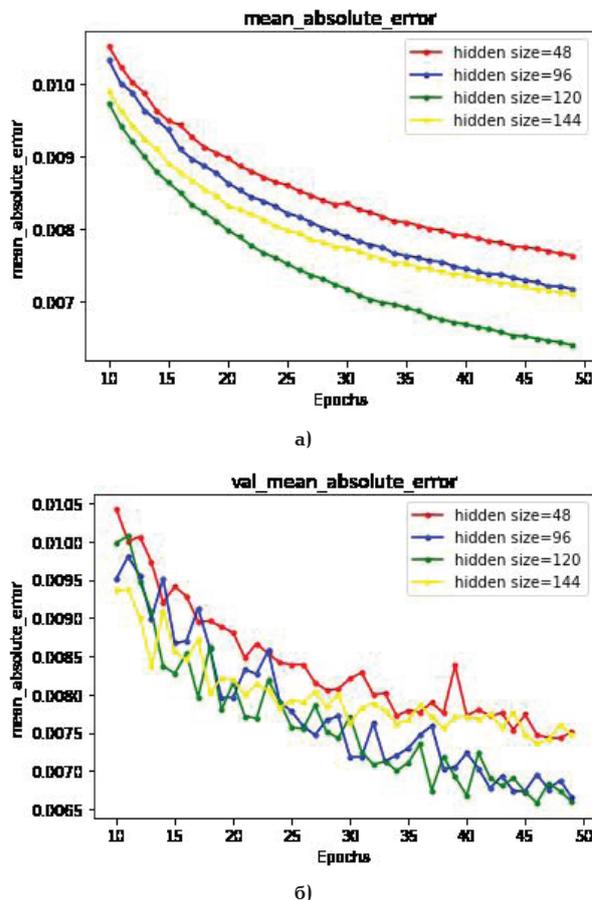


Рис. 2. Кривые обучения одномерной сверточной нейронной сети при различном размере скрытого слоя: а) на обучающей выборке; б) на тестовой выборке

вания моделей в течение 50 эпох обучающего цикла анализируются кривые обучения для нескольких моделей, которые показали наилучшие результаты по окончании обучения. Под кривыми обучения понимаются графики изменения относительной ошибки краткосрочного прогнозирования электропотребления ЭТК РЭС по окончании обучающего цикла.

Рассмотрим алгоритм подбора оптимального значения гиперпараметров для одномерной сверточной нейронной сети с помощью инструментов библиотеки глубокого машинного обучения Keras. Сверточные нейронные сети разрабатывались специально для обработки изображений, однако они применимы и для других данных с сеточной структурой. Сверточные нейронные, как и большинство других нейронных сетей, после слоев свертки и пулинга должны содержать полносвязные слои. Данные слои служат для восстановления векторной регрессии и классификации данных. В случае почасового прогнозирования электропотребления ЭТК РЭС на следующие сутки размер выходного слоя будет составлять 24 элемента, а размер скрытого слоя будет варьироваться. На рис. 2 представлены кривые обучения одномерной сверточной нейронной сети при различном размере скрытого слоя на обучающей и тестовых выборках.

Как мы видим из графиков на рис. 2а, б, модель с 120 нейронами в скрытом слое является наиболее точной.

Далее определим функцию активации в каждом слое данной нейронной сети. На рис. 3 представле-

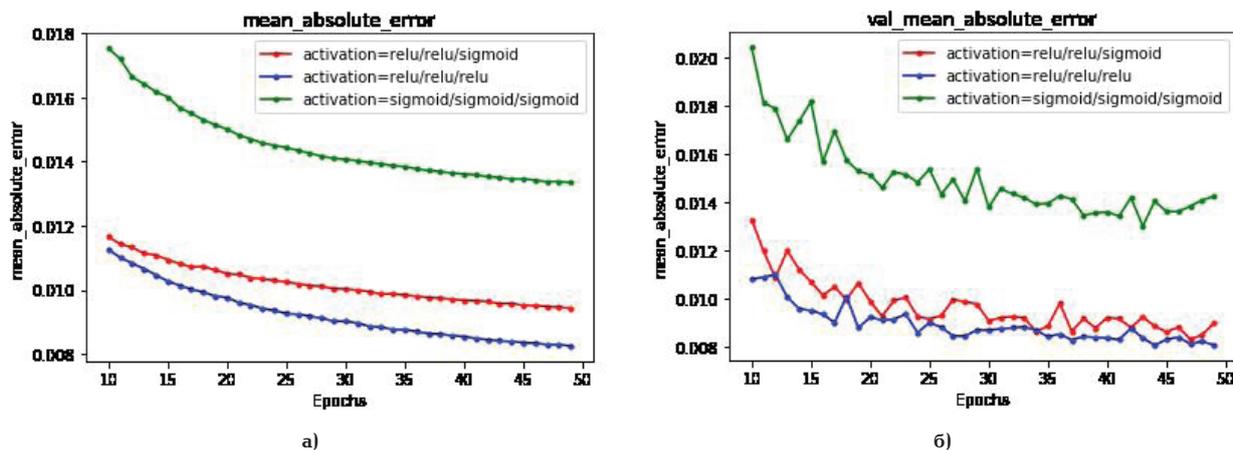


Рис. 3. Кривые одномерной сверточной нейронной сети при различных функциях активации в каждом слое:  
а) на обучающей выборке; б) на тестовой выборке

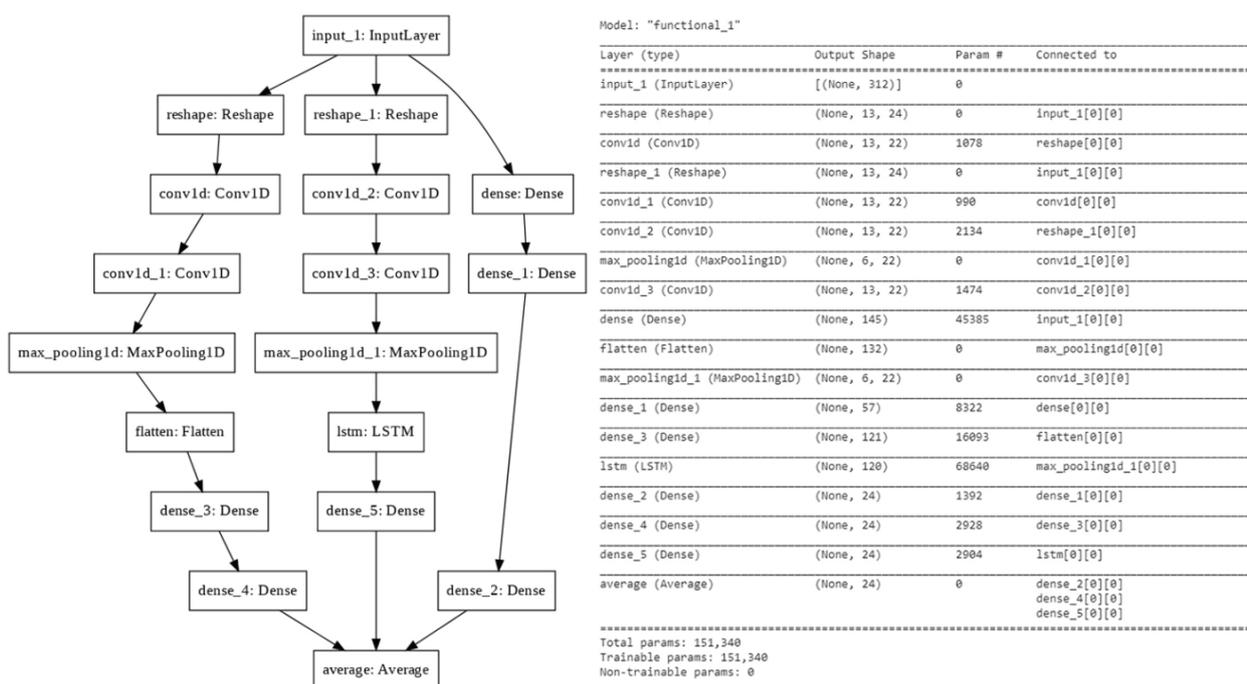


Рис. 4. Структурная схема ансамбля ИНС, используемого для краткосрочного прогнозирования электропотребления ЭТК РЭС

ны кривые обучения одномерной сверточной нейронной сети при различных функциях активации в каждом слое на обучающей и тестовой выборках.

На основании кривых на рис. 3а, б можно сделать вывод о том, что наилучшим вариантом функции активации в каждом слое при краткосрочном прогнозировании электропотребления ЭТК РЭС является кусочно-линейная функция RELU:

$$\varphi(x) = \begin{cases} x, & \text{если } x \geq 0; \\ 0, & \text{если } x < 0. \end{cases} \quad (11)$$

Аналогичным образом определяются другие гиперпараметры нейронной сети.

В ходе данного исследования были разработаны несколько нейросетевых методов краткосрочного прогнозирования электропотребления ЭТК РЭС, в основе которых лежат ИНС следующей архитектуры: многослойный перцептрон (Multilayer

perceptron — MLP), одномерная сеть свертки (Convolution neural network — CNN), рекуррентная сеть типа долгой краткосрочной памяти (Long — short term memory — LSTM), а также ансамбль вышеперечисленных ИНС (Ensemble). Конфигурация каждой ИНС была определена с помощью инструментов библиотеки глубокого машинного обучения Keras. На рис. 4 представлена структурная схема ансамбля ИНС, используемого для краткосрочного прогнозирования электропотребления ЭТК РЭС.

Ансамбль ИНС, представленный на рис. 4, состоит из:

- перцептрона с тремя полносвязными слоями (Dense) размером 145, 57 и 24 нейрона соответственно;

- одномерной сети свертки, состоящей из двух слоев свертки (Conv1D) по 22 ядра размером два элемента, слоя пулинга (Maxpooling1D) и двух полносвязных слоев (Dense) размером 141 и 24 нейрона соответственно;

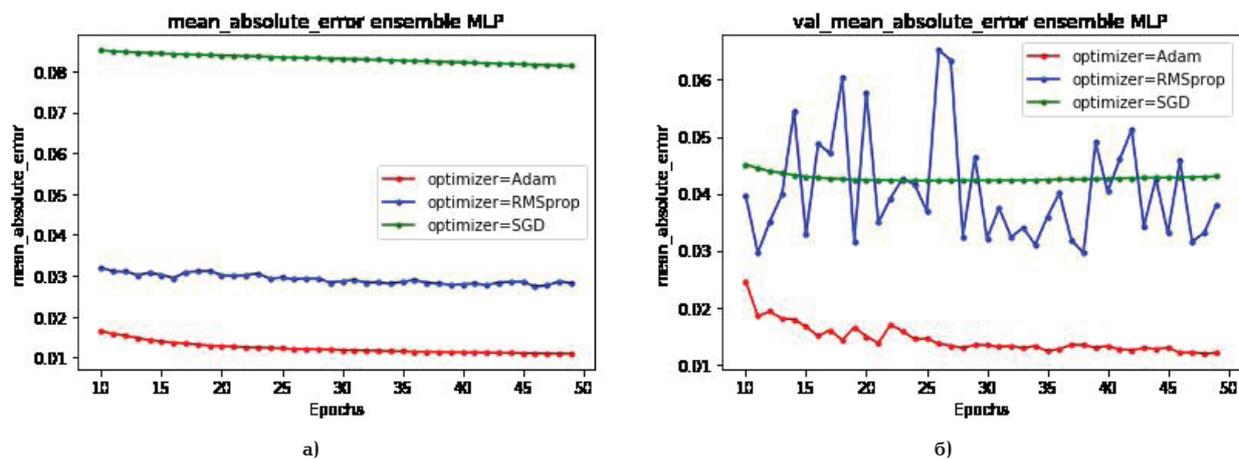


Рис. 5. Графики изменения относительной ошибки прогнозирования электропотребления ЭТК РЭС при использовании различных оптимизаторов функции потерь: а) на обучающей выборке; б) на тестовой выборке

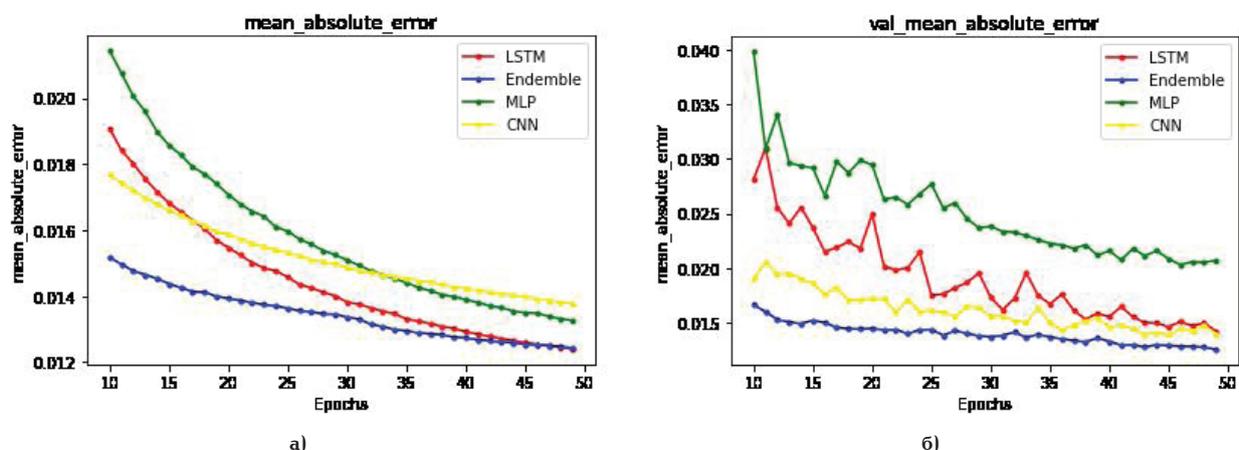


Рис. 6. Кривые изменения ошибки краткосрочного прогнозирования электропотребления ЭТК РЭС разработанных нейросетевых моделей цикла: а) на обучающей выборке; б) на тестовой выборке

— рекуррентной нейросети, состоящей из двух слоев свертки (Conv1D) по 22 ядра размером три и четыре элемента соответственно, слоя пулинга (Maxpooling1D), рекуррентного слоя (LSTM) размером 120 и выходного полносвязного слоя (Dense) размером 24 нейрона.

**Обсуждение результатов исследования.** На рис. 5 представлены графики изменения относительной ошибки прогнозирования электропотребления ЭТК РЭС при использовании различных оптимизаторов функции потерь на обучающей и тестовой выборках данных.

На основании графиков изменения ошибки прогнозирования (рис. 5а, б) можно сделать вывод о том, что использование оптимизатора функции потерь ADAM позволяет снизить ошибку краткосрочного прогнозирования почасового электропотребления ЭТК РЭС на обучающей выборке более чем на 7 % и на тестовой выборке более чем на 3 % по сравнению с алгоритмом стохастического градиентного спуска SGD. В то же время, оптимизатор RMSProp демонстрирует более высокую точность прогнозирования на обучающей выборке, но значительного улучшения результатов на тестовой выборке не наблюдается.

На рис. 6 представлены кривые изменения относительной ошибки краткосрочного прогнозирования

электропотребления ЭТК РЭС разработанных нейросетевых моделей на обучающей и тестовой выборках.

Как мы видим из графиков на рис. 6а, б, применение Ансамбля ИНС при краткосрочном прогнозировании ЭТК РЭС позволяет достичь наибольшей точности на обучающей и тестовых выборках данных по сравнению с одиночными моделями. Увеличение точности прогнозирования по сравнению с многослойным персептроном составляет около 0,2 % на обучающей выборке данных и около 1 % на тестовой выборке данных.

#### Выводы.

В ходе данного исследования было выяснено, что:

— использование адаптивного оптимизатора функции энергии ошибки ADAM позволяет улучшить сходимость алгоритма обучения глубоких нейронных сетей, что, в свою очередь, в значительной степени повышает точность краткосрочного прогнозирования электропотребления ЭТК РЭС;

— современные глубокие нейронные сети, такие как сети свертки и рекуррентные нейросети, демонстрируют более высокую точность краткосрочного прогнозирования электропотребления ЭТК РЭС, по сравнению с устаревшими персептронными нейросетями;

— применение метода краткосрочного прогнозирования потребления электроэнергии ЭТК РЭС, основанного на ансамбле искусственных нейронных сетей, позволило снизить ошибку прогнозирования на 0,3–1 % по сравнению с одиночными нейросетями.

#### Библиографический список

1. Серебряков Н. А. Анализ факторов, влияющих на совокупное электропотребление гарантирующего поставщика // Вестник Иркутского государственного технического университета. 2020. Т. 24, № 2 (151). С. 366–381. DOI: 10.21285/1814-3520-2020-2-366-381.
2. Katasev A. S. Neuro-fuzzy model of fuzzy rules formation for objects state evaluation in conditions of uncertainty // Computer Research and Modeling. 2019. Vol. 11 (3). P. 477–492. DOI: 10.20537/2076-7633-2019-11-3-477-492.
3. Станкевич Т. С. Разработка метода оперативного прогнозирования динамики развития лесного пожара посредством искусственного интеллекта и глубокого машинного обучения // Вестник Иркутского государственного технического университета. 2018. Т. 22, № 9 (140). С. 111–120. DOI: 10.21285/1814-3520-2018-9-111-120.
4. López M., Sans C., Valero S., Senabre C. Empirical comparison of neural network and auto-regressive models in short-term load forecasting // Energies. 2018. Vol. 11 (8). P. 1–19. DOI: 10.3390/en11082080.
5. Zheng H., Yuan J., Chen L. Short-term Load Forecasting Using EMD-LSTM Neural Networks with a Xgboost Algorithm for Feature Importance Evaluation // Energies. 2017. Vol. 10 (8). P. 1–20. DOI: 10.3390/en10081168.
6. Надтока И. И., Хусейн А.-З. Б. М. Краткосрочное прогнозирование электропотребления региона с учетом метеофакторов на основе метода опорных векторов и алгоритма роя частиц // Известия высших учебных заведений. Электро-механика. 2014. № 3. С. 44–47.
7. Кирпичникова И. М., Саплин Л. А., Соломахо К. Л. Прогнозирование объемов потребления электроэнергии // Вестник ЮУрГУ. Серия «Энергетика». 2014. Т. 14, № 2. С. 16–22.
8. Потапов В. И., Грицай А. С., Тюньков Д. А. Спектральный анализ ретроспективных данных ООО «Омская энерго-сбытовая компания» об электропотреблении // Омский научный вестник. 2016. № 5 (149). С. 74–76.
9. Rahman A., Srikumar V., Smith A. D. Predicting electricity consumption for commercial and residential buildings using deep

recurrent neural networks // Applied Energy. 2018. Vol. 212. P. 372–385. DOI: 10.1016/j.apenergy.2017.12.051.

10. Хомутов С. О., Серебряков Н. А. Создание нейросетевой математической модели краткосрочного прогнозирования электропотребления электротехнического комплекса участка районных электрических сетей 6–35 кВ // Транспортные системы и технологии. 2020. Т. 6, № 1. С. 80–91. DOI: 10.17816/trassysyst20206180-91.

11. Жуков А. В., Сидоров Д. Н. Модификация алгоритма случайного леса для классификации нестационарных потоковых данных // Вестник ЮУрГУ. Серия «Математическое моделирование и программирование». 2016. Т. 9, № 4. С. 86–95. DOI: 10.14529/mmp160408.

12. Wang Z., Srinivasan R. S. A review of artificial intelligence based building energy use prediction: contrasting the capabilities of single and ensemble prediction models // Renewable and Sustainable Energy Reviews. 2017. Vol. 75. P. 796–808. DOI: 10.1016/j.rser.2016.10.079.

13. Li S., Wang P., Goel L. A novel wavelet-based ensemble method for short-term load forecasting with hybrid neural networks and feature selection // IEEE Transactions on Power Systems. 2016. Vol. 31, Issue 3. P. 1788–1798. DOI: 10.1109/TPWRS.2015.2438322.

14. Kingma D. P., Lei Ba J. ADAM: a method for stochastic optimization. URL: <https://arxiv.org/pdf/1412.6980.pdf> (дата обращения: 30.01.2017).

**СЕРЕБРЯКОВ Николай Александрович**, старший преподаватель кафедры «Электроснабжение промышленных предприятий».

SPIN-код: 8639-6888

AuthorID (РИНЦ): 1042019

ORCID: 0000-0001-7428-7364

Адрес для переписки: na\_serebryakov@altke.ru

#### Для цитирования

Серебряков Н. А. Применение адаптивного ансамблевого нейросетевого метода для краткосрочного прогнозирования электропотребления электротехнического комплекса районных электрических сетей // Омский научный вестник. 2021. № 1 (175). С. 39–45. DOI: 10.25206/1813-8225-2021-175-39-45.

Статья поступила в редакцию 09.11.2020 г.

© Н. А. Серебряков