

Раздел II. Анализ данных и моделирование

УДК 621.315.611

DOI 10.18522/2311-3103-2025-1-104-118

Н.К. Полуянович, О.В. Качелаев, М.Н. Дубяго

ПОСТРОЕНИЕ МОДЕЛИ И ОЦЕНКА ЕЕ РОБАСТНОСТИ В ЗАДАЧЕ ПРОГНОЗИРОВАНИЯ ДЛЯ ПОТРЕБИТЕЛЕЙ С АДДИТИВНЫМИ ПРОФИЛЯМИ ПОТРЕБЛЕНИЯ ЭЛЕКТРОЭНЕРГИИ

Рассматривается построение робастной модели, оценка ее точности в задачах прогнозирования электрической нагрузки с аддитивными профилями потребления. Проведено исследование влияния параметров нейросети (размер пакета данных; количество слоев нейросети; функции активации нейронов; оптимизаторы) на погрешность прогнозирования электропотребления. Приведены графики сравнения профилей фактического и прогнозного потребления и отклонения прогноза для потребления электроэнергии выше среднего значения за рассматриваемый период. Подобраны оптимальные параметры прогностической нейросетевой модели в ручном режиме. Результат исследования разновидностей генетических алгоритмов выявил оптимальный гибридный алгоритм обучения нейросетевой модели основанный на быстрой сходимости решения. Проведено тестирование созданного на языке "Python" алгоритма подбора гиперпараметров сети на данных об электропотреблении с различными характерами потребления электроэнергии. Проведенное обучение и тестирование генетического алгоритма подтвердило возможность получения прогнозов большей точности и возможность автоматизации подбора оптимальных гиперпараметров. В задачах прогнозирования электропотребления с использованием нейросетевой модели, независимо от способа создания структуры, подобрана оптимальная метрика. Выявлено, что для потребителей с аддитивными профилями потребления электроэнергии целесообразно использовать робастную функцию потерь Хьюбера, в то же время, для потребителей с циклическим или имеющим закономерности профиле потребления электроэнергии применение скользящего окна увеличивает ошибку, в отличии от аддитивных потребителей. Показано, что применение генетического алгоритма значительно увеличивает точность прогнозирования благодаря индивидуальному подбору оптимальных параметров для конкретного потребителя. Разработана структурная схема интеллектуального устройства прогнозирования режимов энергопотребления. Введена система помощи принятия решений, позволяющая реализовать плано-упреждающее управление, основываясь на данных, снимаемых со счетчика электроэнергии и полученных в результате работы нейросетевой модели прогнозирования. Система помощи принятия решений производит расчет отклонения прогнозных величин потребленной мощности от фактических и как результат – выдает рекомендации диспетчеру распределительных энергосетей. На основании данных от системы помощи принятия решений оператор распределительных энергосетей может принимать решение о заказе необходимого объема электроэнергии, получает возможность контролировать возможные всплески и снижения потребления электроэнергии у потребителя, ненормированную работу оборудования, а также дополнительно контролировать адекватность работы нейросетевой модели.

Генетическая нейронная сеть; робастная модель; гибридный алгоритм; аддитивный характер потребителей; прогнозирование электропотребления; упреждающее управление; распределительные сети.

N.K. Poluyanovich, O.V. Kachelaev, M.N. Dubyago

BUILDING A MODEL AND EVALUATING ITS ROBUSTNESS IN THE TASK FORECASTING FOR CONSUMERS WITH ADDITIVE TECHNOLOGIES ELECTRICITY CONSUMPTION PROFILES

The construction of a robust model and an assessment of its accuracy in problems of forecasting electrical loads with additive consumption profiles are considered. A study was conducted on the influence of neural network parameters (data packet size; number of neural network layers; neuron activation func-

tions; optimizers) on the error in predicting power consumption. Graphs comparing the profiles of actual and projected consumption and the deviation of the forecast for electricity consumption above the average value for the period under review are presented. Optimal parameters of the predictive neural network model have been selected in manual mode. The result of the study of the varieties of genetic algorithms revealed the optimal hybrid algorithm for learning a neural network model based on the rapid convergence of the solution. A Python-based algorithm for selecting network hyperparameters based on power consumption data with different patterns of electricity consumption has been tested. The conducted training and testing of the genetic algorithm confirmed the possibility of obtaining forecasts of greater accuracy and the possibility of automating the selection of optimal hyperparameters. In the tasks of forecasting power consumption using a neural network model, regardless of the method of creating the structure, the optimal metric has been selected. It is revealed that for consumers with additive profiles of electricity consumption, it is advisable to use the robust Huber loss function, at the same time, for consumers with a unique or regular profile of electricity consumption, the use of a sliding window increases the error, unlike additive consumers. It is shown that the use of a genetic algorithm significantly increases the accuracy of forecasting due to the individual selection of optimal parameters for a specific consumer. A block diagram of an intelligent device for predicting energy consumption modes has been developed. A decision-making assistance system has been introduced that allows for the implementation of planned proactive management based on data taken from the electricity meter and obtained as a result of the neural network forecasting model. The decision-making assistance system calculates the deviation of the projected power consumption values from the actual ones and, as a result, issues recommendations to the dispatcher of the distribution power grids. Based on data from the decision-making assistance system, the distribution grid operator can make a decision on ordering the required amount of electricity, gets the opportunity to monitor possible spikes and decreases in consumer electricity consumption, abnormal equipment operation, and additionally monitor the adequacy of the neural network model.

Genetic neural network; robust model; hybrid algorithm; additive nature of consumers; forecasting of power consumption; proactive management; distribution networks.

Введение. Актуальность стратегических приоритетов и цели государственной политики в сфере реализации комплексной государственной программы Российской Федерации для современных предприятий были обозначены в постановлении Правительства РФ от 9 сентября 2023 г. N 1473 "Об утверждении комплексной государственной программы Российской Федерации "Энергосбережение и повышение энергетической эффективности" [1–3]. Учитывая значительный физический износ оборудования, высокие показатели удельных расходов топлива и потерь в сетях проводится модернизация предприятий, генерирующих электрическую энергию, устанавливаются приборы учета. Согласно Указа Правительства РФ ставится задача глобального уровня, направленная на снижение энергоемкости на 40% относительно показателей за две тысячи седьмой год. Мероприятия, нацеленные на увеличение энергоэффективности, увеличение прибыли, за счет снижения убытков предприятий, выполняющих задачи в отрасли электроэнергетики, начинают производиться в настоящее время. Важнейшей задачей становится прогнозирования потребленных объемов электроэнергии, в разрезе мероприятий, направленных на оптимизацию электроэнергетических затрат предприятия. Проблема прогнозирования электропотребления заключается в том, что необходимо учесть огромное количество факторов, имеющих влияние на изменение энергопотребления [4, 5]. По оценкам российских специалистов, каждая оплошность в ежегодном прогнозе электропотребления на 1% – это 4 млрд. долларов дополнительных инвестиций на возведение генерирующих мощностей [6]. Целью прогнозирования электропотребления является обеспечение баланса между выработанной и потребленной электроэнергией [7].

Постановка задачи. Разработка оптимальной структуры системы прогнозирования для потребителей с атипичным характером электропотребления т.е. не повторяющимся значением профилей потребляемой (P, Q) за рассматриваемые периоды времени, а также математической модели прогнозируемого объема электропотребления, включающей в себя кроме целевых параметров электросети (P, Q) учет воздействующих факторов: социально-экономических; технологических и метеорологических.

Обзор литературных источников. Методы прогнозирования электропотребления на основе регрессионного анализа описаны в работах Манусова В.З. и Никифорова Г.В., применительно к краткосрочному прогнозированию объемов потребления электроэнер-

гии. Прогнозированием пробоя в электроизоляции на основе ИНС было предложено Поляковым Д.А. Прогнозированию электропотребления посвящены работы Воронова И.В. и Демура, А.В. Применение метода экспоненциального сглаживания в задачах прогнозирования было предложено Клеопатровым Д.И. Лагуткин, О.Е. предложил метод на основе техноценоза. Влияние точности прогнозов потребления на технологические и экономические показатели энергосистемы рассмотрено в работе [8]. Для обеспечения минимального расхода электроэнергии, предотвращения перегрузок на электрооборудовании и в электросетях, а также улучшения качества электроэнергии энергосистемам необходимо повышать точность прогноза [9].

Однако, в случае с потребителями с атипичным характером потребления электроэнергии, предложенные методы не могут быть полноценно применены. Причиной являются такие ограничения как: большой период времени, за который собираются статистические выборки и отсутствие возможности применения большого количества влияющих факторов.

Задачам создания интеллектуальных устройств прогнозирования энергопотребления посвящено много работ. Так в [10] указывается возможность использования нейронной сети прямой связи для прогнозирования электропотребления. Однако данный метод не позволяет: учитывать реактивную мощность, учитывать данные о метеорологических параметрах; нет механизма адаптации. Для прогнозирования кратко- и среднесрочных объемов потребления электроэнергии может применяться «Устройство прогнозирования электропотребления на основе многослойной нейронной сети» [11]. Данное устройство может обеспечить формирование значений на основе разности фактических и аппроксимированных значений потреблённой электроэнергии. Данный факт положительно сказывается на точности прогнозирования, путем сужения интервала необходимой нормализации данных. Однако недостатком данного устройства являются отсутствие механизма адаптации. «Устройство мониторинга и прогнозирования электропотребления в электроэнергетических системах на основе нейронных структур» [12], не учитывает данные о внешних воздействующих факторах, таких как: скорость ветра; наличие осадков; отсутствие блока адаптации под конкретного потребителя (учет характера кривой потребления электроэнергии) и подстройки устройства в зависимости от получаемой точности прогнозирования. Таким образом встает задача разработки интеллектуального устройства адаптивного прогнозирования режимов энергопотребления электросети.

Алгоритм обучения НС. Классическим алгоритмом обучения нейронной сети [13] считается алгоритм обратного распространения ошибки. Процесс обучения нейронной сети итерационный – предполагается, что обучение происходит в течение некоторого количества эпох, при этом в рамках одной эпохи нейронной сети предъявляются все объекты обучающей выборки [14]. Для каждого нейрона j на слое n ($n > 1$) его выходное значение $o_j^{(n)}$ определяется в соответствии с выражением

$$o_j^{(n)} = \varphi(s_j^{(n)}). \quad (1)$$

Тогда выходные значения нейронной сети будут вычисляться как

$$y_k = \varphi(s_j^{(N)}). \quad (2)$$

Таким образом, значения на выходном слое сети зависят от всех весовых коэффициентов. Изначально все весовые коэффициенты сети инициализируются достаточно малыми случайными числами. Согласно [15] существует три варианта корректировки весовых коэффициентов нейронной сети в рамках одной эпохи. Первый из них предполагает корректировку после предъявления каждого объекта из обучающей выборки; второй предполагает разделение обучающей выборки на части (обычно равные) и корректировку весов после предъявления каждой такой части; в третьем варианте корректировка весов выполняется после предъявления всех объектов обучающей выборки. В данной работе рассматривается первый вариант, в связи с чем суммарная функция потерь E может быть представлена как сумма значений функций потерь $f(t_j, y_j)$ на каждом выходе нейронной сети. Поэтому обучение сети сводится к решению следующей задачи оптимизации:

$$E = \sum_{j=1}^{l^{(N)}} f(t_j, y_j) \rightarrow \min_{\omega_{ij}^{(1)}, \dots, \omega_{ij}^{(N-1)}}, \quad (3)$$

где t_j – требуемый ответ на j -м выходе сети – определяется следующим образом

$$t_j = \begin{cases} 1, & X_m \in q_j \\ 0, & \text{иначе} \end{cases}.$$

Как правило, в качестве функции потерь используется квадратичная функция:

$$f(t_j, y_j) = \frac{1}{2}(y_j - t_j)^2. \quad (4)$$

Будем называть нейронные сети, построенные с использованием квадратичной функции потерь, классическими. Для минимизации суммарной функции потерь необходимо вычислить её производную по весам нейронной сети. Исходя из (1) и (2), частная производная (3) вычисляется по следующему цепному правилу [15]:

$$E'_{ji}{}^{(n)} = \frac{\partial E}{\partial \omega_{ij}^{(n-1)}} = \frac{\partial E}{\partial o_j^{(n)}} \frac{\partial o_j^{(n)}}{\partial s_j^{(n)}} \frac{\partial s_j^{(n)}}{\partial \omega_{ij}^{(n-1)}}. \quad (5)$$

Во входном значении нейрона $s_j^{(n)}$ от $w_{ij}^{(n-1)}$ зависит только одно слагаемое, таким образом

$$\frac{\partial s_j^{(n)}}{\partial \omega_{ij}^{(n-1)}} = \frac{\partial}{\partial \omega_{ij}^{(n-1)}} \left(\sum_{i=1}^{l^{(n-1)}} \omega_{ij}^{(n-1)} o_i^{(n-1)} \right). \quad (6)$$

Производная выходного значения нейрона $o_j^{(n)}$ по его входному значению $s_j^{(n)}$ – это производная функции активации:

$$\frac{\partial o_j^{(n)}}{\partial s_j^{(n)}} = \frac{d\varphi(s_j^{(n)})}{ds_j^{(n)}}. \quad (7)$$

Если нейрон находится на выходном слое, то $n = N$ и первый множитель в (5) можно легко вычислить, поскольку $o_j^{(N)} = y_j$:

$$\frac{\partial E}{\partial o_j^{(N)}} = \frac{\partial E}{\partial y_j} = \frac{\partial f(y_j, t_j)}{\partial y_j}. \quad (8)$$

Теперь получим выражение для производной E по $o_j^{(n)}$ в случае, когда n – произвольный внутренний слой сети. Для этого рассмотрим E как функцию от входных значений нейронов следующего слоя:

$$E = E(s_k^{(n+1)}), k = 1, \dots, l^{(n+1)},$$

а затем возьмем производную по $o_j^{(n)}$ [15]:

$$\frac{\partial E}{\partial o_j^{(n)}} = \sum_{k=1}^{l^{(n+1)}} \left(\frac{\partial E}{\partial s_k^{(n+1)}} \frac{\partial s_k^{(n+1)}}{\partial o_j^{(n)}} \right) = \sum_{k=1}^{l^{(n+1)}} \left(\frac{\partial E}{\partial s_k^{(n+1)}} \frac{\partial s_k^{(n+1)}}{\partial o_j^{(n)}} \right) w_{jk}^{(n)}. \quad (9)$$

Производную (9) можно вычислить, если известны все производные по выходным значениям для следующего слоя. Таким образом, производная суммарной функции потерь будет вычисляться в соответствии с

$$E'_{ji}{}^{(n)} = \delta_j^{(n)} o_i^{(n-1)}, \quad (10)$$

где $\delta_j^{(n)}$, исходя из (5-9), вычисляется следующим образом:

$$\delta_j^{(n)} = \frac{\partial E}{\partial o_j^{(n)}} = \begin{cases} \frac{\partial f(y_j, t_j)}{\partial y_j} \varphi'(y_j), & n = N, \\ \left(\sum_{k=1}^{l(n+1)} w_{jk}^{(n)} \delta_k^{(n+1)} \right) \varphi'(s_j^{(n)}), & \text{иначе.} \end{cases} \quad (11)$$

Поскольку соотношение для вычисления производной известно, для решения задачи оптимизации можно воспользоваться методом градиентного спуска [15]. В этом случае корректировка весов $w_{ij}^{(n-1)(p)}$ на итерации p имеет вид:

$$\omega_{ij}^{(n-1)p} = \omega_{ij}^{(n-1)(p-1)} + \Delta \omega_{ij}^{(n-1)p}. \quad (12)$$

В данном соотношении $\Delta w_{ij}^{(n-1)(p)}$ вычисляется как

$$\Delta \omega_{ij}^{(n-1)p} = -\eta E_{ji}'^{(n)(p)} = -\eta \delta_j^{(n)(p)} o_i^{(n-1)(p)}, \quad (13)$$

где $\eta > 0$ – скорость обучения сети, $E_{ji}'^{(n)(p)}$ – производная суммарной функции потерь на итерации p , а $\delta_j^{(n)(p)}$ на итерации p вычисляется в соответствии с соотношением (11), в котором вместо весов $w_{jk}^{(n)}$ используются веса $w_{jk}^{(n-1)(p)}$

При реализации алгоритма обратного распространения ошибки в качестве функции активации $\varphi = \varphi(z)$ часто используют одну из функций, описанных в [20].

Следует отметить, однако, что последняя из перечисленных функций (ReLU) чаще используется в более сложных нейронных сетях (при глубоком обучении). К тому же она обладает существенным недостатком: нулевая производная на части области определения может привести к тому, что корректировка весов не будет оказывать никакого эффекта и модель перестанет обучаться [16]. Как правило, в нейронных сетях с простой архитектурой отдадут предпочтение сигмоидальной функции активации или гиперболическому тангенсу.

Интеллектуальное устройство предупреждающего прогнозирования режимов энергопотребления и помощи в принятии решений. Встает задача создания приборов непрерывного мониторинга и прогнозирования энергопотребления, с учетом факторов времени, метеорологических условий, отключений отдельных питающих линий электропередач, режима работы потребителей электроэнергии в реальном времени. Преимуществом предлагаемой модели (рис. 1) является непрерывный мониторинг и прогнозирование энергопотребления в реальном режиме времени с применением системы помощи принятия решений, передающей информацию ($P_{\text{прог}}$, $Q_{\text{прог}}$, ϵ) для оценки потребления и формирование заявки на закупку электроэнергии в диспетчерское управление распределительными энергосетями (ДУ РЭС), автоматизированный подбор гиперпараметров НС-модели при помощи генетического алгоритма (ГА).

Оценка точности прогнозирования, осуществляется по формуле (14):

$$E = \frac{|\sum P_{\text{прог}} - \sum P_{\text{потр}}|}{\sum P_{\text{потр}}} * 100, \quad (14)$$

Обработка данных в блоке БД (3) включает:

1. Нормализацию: Для увеличения информативности данных при обучении нейросети, что обеспечивает также увеличение точности прогнозирования применяется нормализация на основе формулы максимума-минимума (15):

$$P_{\text{норм}} = \frac{P_{\text{факт}} - P_{\text{min}}}{P_{\text{max}} - P_{\text{min}}}, \quad (15)$$

где $P_{\text{факт}}$ – нормируемое значение, P_{min} – минимальное значение P в массиве данных, P_{max} – максимальное значение P в массиве данных.

2. Сглаживание: Для улучшения стабильности и скорости сходимости применяется метод сглаживания вектора значений. Сглаживание входных данных реализуется по формуле (16):

$$P_{\text{стл}} = \frac{P_n + P_{n+1}}{2}, \quad (16)$$

где $P_{\text{стл}}$ – сглаженное значение, P_n, P_{n+1} – значение мощности, n – значение временного шага.

3. Формирование выборки: Запись поступающих данных в файл Excel, соблюдая порядок параметров, подаваемых на входные нейроны НС.

На рис. 1 приведена структурная схема интеллектуального устройства упреждающего прогнозирования режимов энергопотребления и помощи принятия решений, состоящая из: 1 – блока подсистемы прогнозирования, 2 – блока СППР (система поддержки принятия решений), 3 – ГА (генетический алгоритм) подбора структуры НС, 4 – блока обучения НС, 5 – блока подбора гиперпараметров, 6 – блока оценки приспособленности НС, 7 – блока НС-модель прогнозирования, 8 – блока хранения данных, 9 – блока обработка данных, 10 – блока вывода рекомендаций, 11 – блок анализа ЭП (электропотребления).

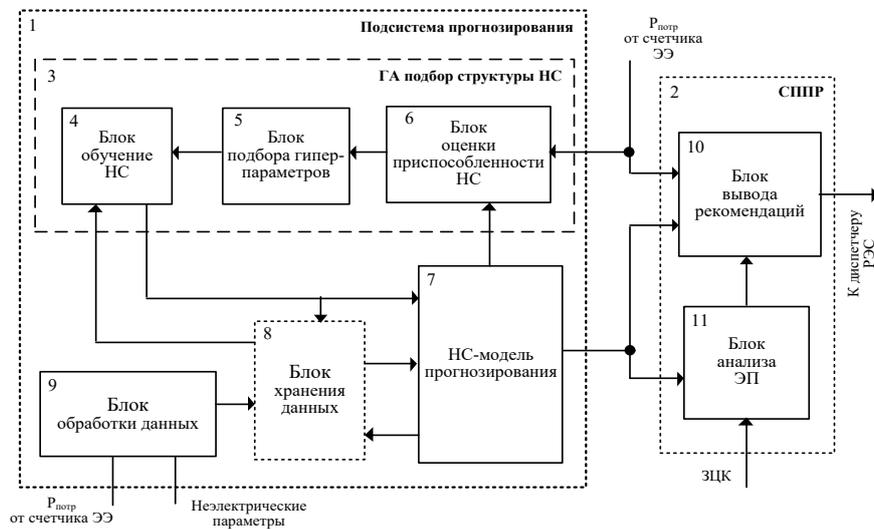


Рис. 1. Структурная схема интеллектуального устройства упреждающего прогнозирования режимов энергопотребления

На рис. 2 приведен график сравнения кривой фактического и прогнозного потребления и отклонения прогноза для потребления ЭЭ выше среднего значения за рассматриваемый период.

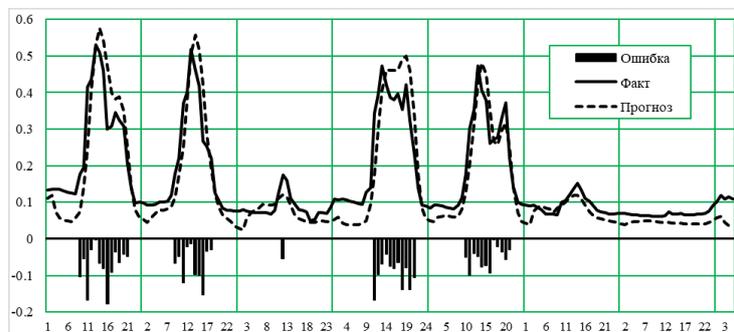


Рис. 2. Графики сравнения фактического, спрогнозированного электропотребления и отклонения от прогноза

Работает устройство следующим образом. Значения потреблённой мощности, снимаемые со счетчика электроэнергии, поступают в блок обработки данных (9), в блок оценки приспособленности НС (6) и в блок вывода рекомендаций (10). Регистрируемые неэлектрические параметры также поступают в блок обработки данных (9). Блок хранения данных (8) принимает данные из блока обработки данных (9), хранит в себе значения потреблённой электроэнергии и формирует выборки данных, а также хранит лучшие НС-модели с различными конфигурациями гиперпараметров. Блок обучения НС (4) выполняет подбор гиперпараметров НС-модели при помощи генетического алгоритма (рис. 3) и обучение с использованием метода обратного распространения ошибки. Обученная модель направляется в блок НС-модель прогнозирования (7). Команду на начало обучения блок может получить как вручную, так и как результат работы блока оценки приспособленности НС (6).

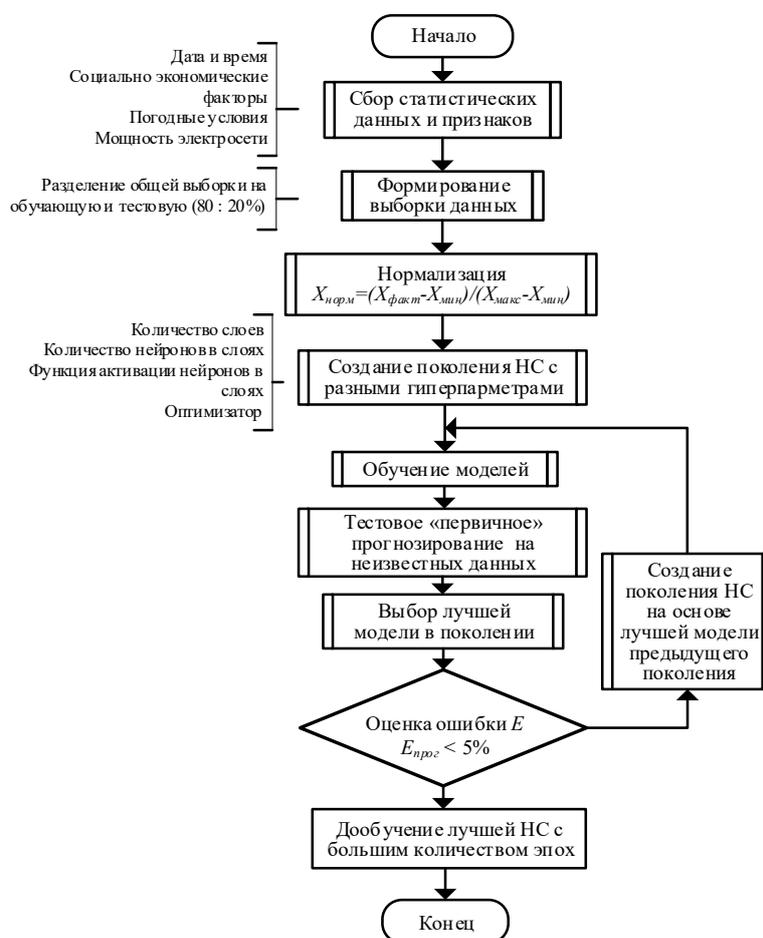


Рис. 3. Генетический алгоритм работы устройства упреждающего прогнозирования режимов энергопотребления и помощи принятия решений

Блок оценки приспособленности НС (6) производит расчет ошибки прогнозирования на основании значений, полученных из блока НС-модель прогнозирования (7) и фактического значения потреблённой ЭЭ, снимаемых со счетчиков электроэнергии. В случае, когда рассчитанное значение ошибки превышает заданное, блок оценки приспособленности НС (6) подает команду на начало подбора гиперпараметров в блок (5), далее производится обучение НС-модели в блоке обучения НС.

Система помощи принятия решений работает следующим образом:

Блок анализа ЭП (11) выполняет сравнение объема заказанной ЭЭ ($P_{\text{зад}}$) и прогноз-ного значения потребленной ЭЭ ($P_{\text{прог}}$) за обозреваемый период. Рассчитанная погреш-ность (ϵ_p) направляется в блок вывода рекомендаций (10).

Блок вывода рекомендаций (10) производит расчет отклонения прогнозных величин потребленной мощности ($P_{\text{прог}}$) от фактических ($P_{\text{потр}}$) на основании данных, снимаемых со счетчика ЭЭ и полученных в результате работы блока НС-модель прогнозирования (7). Производит обработку и преобразование данных, поступающих к диспетчеру РЭС в удобный вид.

Из блока вывода рекомендаций (10) снимаются следующие данные: $F_{\text{рф}}$ (фактиче-ская потребленная мощность), $P_{\text{прог}}$ (прогнозная мощность) ϵ_p (ошибка прогнозирова-ния) графики зависимости $P_{\text{прог}}(t)$ и $P_{\text{факт}}(t)$, график отклонения прогноза для потребления ЭЭ выше среднего значения за рассматриваемый период (фиг. 2), сообщения об увеличе-нии отклонения прогнозирования больше заданного предела и начале переобучения.

На основании полученных данных оператор РЭС принимает решение о заказе необ-ходимого объема ЭЭ ($\sum P_{\text{прог}}$), получает возможность контролировать возможные вспле-ски и снижения потребления ЭЭ у потребителя, ненормированную работу оборудования, а также дополнительно контролировать адекватность работы НС-модели.

Генетический алгоритм оптимизации гиперпараметров НС-модели, приведенный на рис. 3, включает в себя следующие этапы:

1. Сбор ключевых статистических данных и признаков, необходимых для прогноза:
 - a. показания мощности электропотребления ($P_{\text{потр}}$, $Q_{\text{потр}}$);
 - b. погодные условия (Дождь, ветер, температура) (R , W , T);
 - c. дата и время снятия показаний (D , M , Y , t);
 - d. статус дня (Рабочий / Выходной день) (S) (1/0).
2. Формирование выборки данных.
3. Нормализация данных – значения данных нормализуются в области определения $[0, 1]$:

$$X_{\text{норм}} = (X_{\text{факт}} - X_{\text{min}}) / (X_{\text{max}} - X_{\text{min}}).$$

Нормализация проводится с целью увеличения информативности данных для НС и снижения влияния значений, изменяющихся в слишком большом или в слишком малом диапазоне.

4. Создание поколения НС с разными гиперпараметрами. Создается поколение ней-ронных сетей, которые будут иметь случайно заданные гиперпараметры – хромосомы в которые входят:

- a. количество слоев в НС (j);
- b. количество нейронов в слое (n);
- c. функция активации нейронов для каждого слоя (F_a);
- d. оптимизатор, используемый при обучении (O).

Популяция – набор всех пробных решений (особей) в поколении. Размер популяции (НС-модели с различным набором гиперпараметров – хромосом) и поколения задается вручную.

Поколение n нейронных сетей с гиперпараметрами задается следующими массивами:

$$T_m [l_1, l_2, \dots, l_n],$$

где длина массива T указывает на количество слоев в НС, а каждый элемент массива обо-значает количество нейронов в j слое:

$$F_m [f_1, f_2, \dots, f_n].$$

где длина массива F соответствует количеству слоев в НС, а каждый элемент массива обозначает функцию активации для каждого j слоя:

$$O [o_1, o_2, \dots, o_m].$$

Массив номеров оптимизаторов, где длина массива указывает на количество НС в поколении.

Каждая m модель НС создается, с использованием гиперпараметров записанных в массивы:

$$F_m, T_m, O[o_m].$$

5. Цикл обучения нейронных сетей методом обратного распространения ошибки с использованием генетического алгоритма. Цикл включает в себя:

- ◆ обучение НС с использованием метода обратного распространения ошибки;
- ◆ проверка НС на тестовой выборке;
- ◆ выбор лучшей НС из поколения.

6. Сравнение результата с желаемым проводится вручную оператором, с целью получения наибольшей точности.

- a. Если результат не удовлетворительный, то запускаем процесс обучения НС на основе лучшей модели предыдущего поколения. И переходим к пункту 5.
- b. Если результат удовлетворительный, то повторно обучаем лучшую НС в течении большего количества эпох, чтобы увеличить точность прогноза.

Суть оптимизации с использованием ГА заключается в автоматизированном подборе наиболее оптимальных гиперпараметров нейронной сети для выполнения конкретной задачи. Преимуществом предлагаемого устройства, перед известными, является:

1) увеличение точности прогнозирования благодаря возможности НС-модели приспособиваться к конкретному потребителю энергии, благодаря введению ГА подбора гиперпараметров НС-модели;

2) ввод блока СППР, позволяет: выявлять тенденцию изменения ЭП; реализовать систему упреждающего управления ЭП, учитывающую воздействующие факторы (метео; социально-экономические; режимы работы оборудования);

3) введение блока подсистема прогнозирования и СППР повышает эффективность работы электросети благодаря предоставлению необходимой оператору ДУ РЭС информации для принятия решений;

4) ввод блока анализа ЭП, выполняющего расчет погрешности соответствия заказанной ЭЭ и прогнозной позволяет своевременно корректировать необходимый объем ЭЭ, тем самым сокращая финансовые затраты на покупку ЭЭ.

Оценка качества работы нейронной сети. Для оценки качества работы нейросетевых моделей существует множество различных метрик. При построении модели и оценке ее работоспособности крайне важным является выбрать корректную (соответствующую задаче и природе данных) метрику [18]. Для задач регрессии применяются следующие метрики [17, 18]. Исследовано влияние различных метрик на точность прогнозирования электропотребления для данных с аддитивным профилем. Рассматривалось три присоединения, в качестве функции потерь использовалась функция Хьюбера. При исследовании использовалась НС-модель с экспериментально установленной структурой: кол-во скрытых слоев – 3; кол-во нейронов на слой – 40 40 30; BatchSize – 250; кол-во эпох – 60; функция активации – ReLU для всех слоев. Исследовались такие метрики как: Accuracy и MAE. Результаты расчета средней погрешности прогнозирования электроэнергии для различных потребителей (AP-103, AP-204, AP-304) сведены в табл. 1.

Таблица 1

Погрешности прогнозирования при различных метриках

Метрика	Погрешность (средняя), %		
	AP-103 присоединение	AP-204 присоединение	AP-304 присоединение
MAE	3.6	1.53	14.93
Accuracy	0.92	19.48	1.03

На рис 4. приведены графики сравнения полученных прогнозных и фактических значений электропотребления (за месяц) при использовании различных метрик, для одного из потребителей (AP-103).

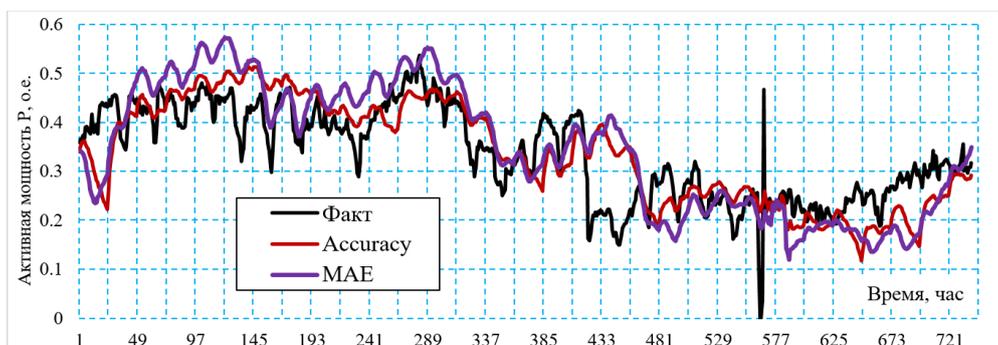


Рис. 4. Графики сравнения прогнозных и фактических значений для AP-103

Построение робастной НС-модели и оценка точности ее прогноза. Исследовано влияние на погрешность прогнозирования ЭП применения робастных функций потерь вместо классической MSE. Робастный подход, является альтернативой классическим методам. Он позволяет не исключать нетипичные наблюдения, а снизить их негативное влияние при обучении модели и, тем самым, добиться достаточно высокой точности работы модели при анализе зашумленных данных. При решении других задач машинного обучения, однако, такой подход до сих пор используется не очень часто. [18]. В работе рассматривались такие робастные функции потерь как:

1) Хьюбера

$$\begin{cases} \frac{1}{2}z^2, & |z| \leq \beta \\ \beta|z| - \frac{1}{2}\beta^2, & |z| > \beta \end{cases}$$

2) Коши (Лоренца)

$$\ln\left(\frac{1}{2}\left(\frac{z}{\beta}\right)^2 + 1\right).$$

Тестирование применимости робастной функции производилось с использованием двух способов формирования нейросети:

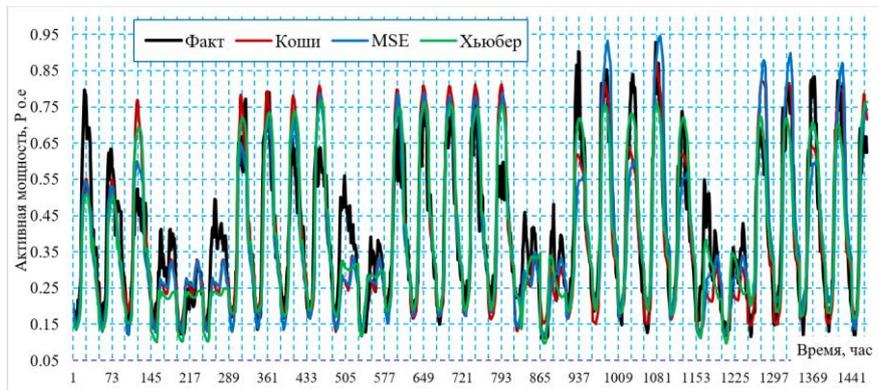
1. Создание НС фиксированной структуры, задаваемые параметры: кол-во скрытых слоев – 3; кол-во нейронов на слой – 40 40 30; BatchSize – 250; кол-во эпох – 60; функция активации – ReLU для всех слоев.

2. Создание НС при помощи разработанного генетического алгоритма подбора параметров.

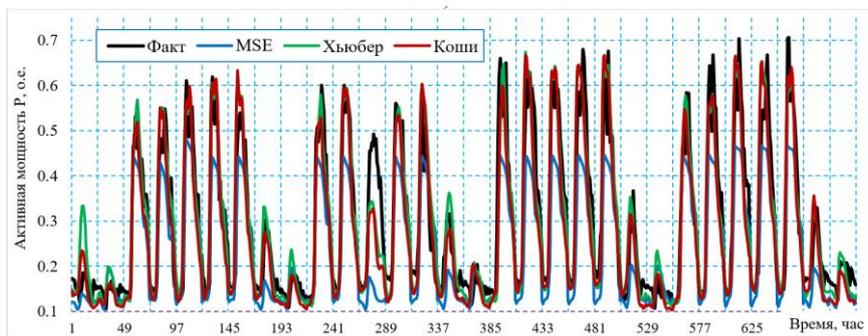
Исследовались потребители со следующими профилями ЭП: 1 – циклический; 2 – аддитивный; 3 – аддитивно-сезонный; 4 – аддитивно случайный.

Для одного типа потребителя (с различным профилем потребления) приведены графики сравнение фактического электропотребления и спрогнозированного нейросетью, с использованием функций потерь MSE, Хьюбера и Коши, рис. 5.

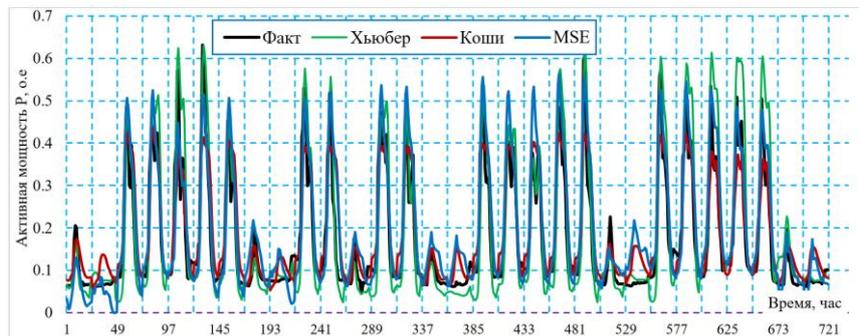
Проведен расчет ошибки прогнозирования (за месяц) при использовании различных функций потерь, табл. 2.



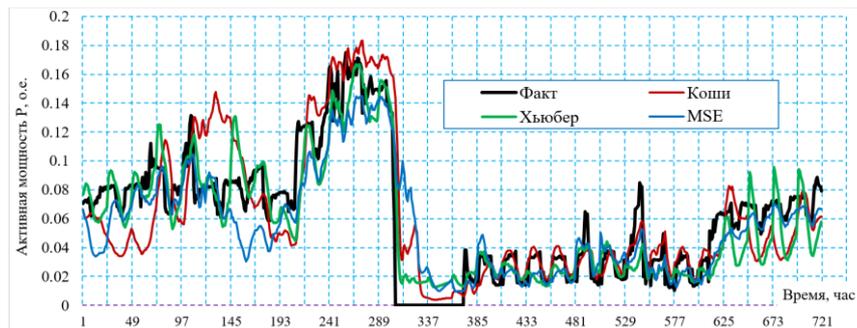
а



б



в



г

Рис. 5. Сравнение графиков прогноза и фактического ЭП для потребителя:
 а – с циклическим профилем; б – с аддитивно-случайным профилем;
 в – с аддитивно-сезонным профилем; г – с аддитивным профилем

Таблица 2

Ошибка прогнозирования при использовании различных функций потерь

Характер потребления электроэнергии		Погрешность прогнозирования, %											
		Циклический		Аддитивно-случайный		Аддитивно-сезонный		Аддитивный (МАКР)					
								AP-103		AP-204		AP-304	
Без СО и ГА	ГА без СО	Без ГА, со СО	ГА без СО	Без СО и ГА	Без СО и ГА	Без СО и ГА	Без СО и ГА	ГА+СО	СО без ГА	ГА+СО	СО без ГА	ГА+СО	
Месяц	MSE	5.75	3.56	4.07	2.42	20.5	8.08	5.58	2.04	11.08	7.97	10.11	9.9
	Хьюбер	5.46	1.16	9.78	0.38	11.7	2.77	2.48	1.3	4.97	3.55	6.06	3.77
	Коши	5.77	3.1	8.4	5.02	12.26	6.93	9.8	8.78	20.7	12.19	8.01	7.51

Анализ результатов проведенного исследования показал:

- ♦ Для потребителей ЭЭ с циклическим профилем лучше всего себя показывают функции потерь MSE и Хьюбера, снижение ошибки до 2%. Важно отметить, что для потребителей с циклическим профилем и в случаях, где прослеживается закономерность в потреблении ЭЭ, применение скользящего окна вызывает значительное увеличение ошибки.

- ♦ Для потребителя с аддитивно-случайным профилем без использования ГА лучше всего показала себя функция потерь MSE, снижение ошибки до 4%.

- ♦ Для потребителя с аддитивно-сезонным профилем применение СО без генетического алгоритма вызывает значительное снижение точности прогнозирования вплоть до 60-70%. Без использования ГА лучше всего показала себя функции потерь Хьюбера и Коши, снижение ошибки до 9%.

- ♦ Для потребителей с аддитивным профилем наибольшую эффективность показала робастная функция потерь Хьюбера. Снижение точности по сравнению с MSE – до 6-7%. Для потребителей с таким профилем целесообразно использовать метод СО, который положительно сказывается на точности прогнозирования.

- ♦ Использование ГА подбора гиперпараметров НС позволяет добиться снижения ошибки прогнозирования в среднем на 8%. Следует отметить необходимость дообучения созданной НС-модели на большем количестве эпох (700-800). BatchSize устанавливается либо использованный во время работы ГА – в данном случае 250, либо меньше – 150-200.

Заключение. В задачах прогнозирования электропотребления с использованием нейросетевой-модели, независимо от способа создания структуры, выявлено что, наилучшей метрикой является метрика MAE, по сравнению с ассигасу в среднем до 9%. Для потребителей с аддитивными профилями потребления электроэнергии целесообразно использовать робастную функцию потерь Хьюбера, а для потребителей с циклическим или имеющим закономерности профиле потребления электроэнергии применение скользящего окна увеличивает ошибку, в отличии от аддитивных потребителей; применение генетического алгоритма значительно увеличивает точность прогнозирования благодаря индивидуальному подбору оптимальных параметров для конкретного потребителя. Новизной разработанной структуры интеллектуального устройства прогнозирования режимов энергопотребления, является система помощи принятия решений, позволяющая реализовать планово-упреждающее управление, основываясь на данных, снимаемых со счетчика электроэнергии и полученных в результате работы нейросетевой модели прогнозирования. Преимуществом системы помощи принятия решений является расчет отклонения

прогнозных величин потребленной мощности от фактических и как результат – выдача лицу, принимающему решение, распределительных энергосетей рекомендации. Информационные данные от системы помощи принятия решений помогают оператору распределительных энергосетей принимать взвешенное решение о заказе необходимого объема электроэнергии, контролировать вероятные всплески и снижения потребления электроэнергии у потребителя, ненормированную работу электрооборудования.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Постановление Правительства РФ от 9 сентября 2023 г. N 1473 "Об утверждении комплексной государственной программы Российской Федерации "Энергосбережение и повышение энергетической эффективности" // Размещен в СПС "Консультант Плюс". – <https://base.garant.ru/407632842/>.
2. *Полуянович Н.К.* Монтаж, наладка, эксплуатация и ремонт систем электроснабжения промышленных предприятий. Сер. учебники для вузов. Специальная литература. – 3-е изд., стереотипное. – СПб., 2017.
3. *Родыгина С.В.* Проектирование и эксплуатация систем электроснабжения. Передача, распределение, преобразование электрической энергии: учеб. пособие. – Новосибирск: Изд-во НГТУ, 2017. – 72 с.
4. *Серебряков Н.А., Хомутов С.О.* Анализ случайной составляющей временного ряда электрической нагрузки группы точек поставки электроэнергии сельхозпроизводителей // Вестник Алтайского государственного аграрного университета. – 2019. – № 5 (175). – С. 153-158.
5. *Полуянович Н.К., Дубяго М.Н.* Оценка воздействующих факторов и прогнозирование электропотребления в региональной энергосистеме с учетом режима ее эксплуатации // Известия ЮФУ. Технические науки. – 2022. – № 2 (226). – С. 31-46.
6. *Рудаков Е., Саакян Ю., Нигматулин Б., Прохорова Н.* Цена расточительности // Эксперт. – Июнь 2008. – № 24.
7. *Билалова А.И.* Статистика потребления электроэнергии в г. Ульяновск // Вузовская наука в современных условиях: Сб. материалов 48-й научно-технической конференции. – Ульяновск: УлГТУ, 2013. – С. 15-18.
8. *Доманов В.И., Билалова А.И.* Прогнозирование объемов энергопотребления в зависимости от исходной информации // Вестник ЮУрГУ. Серия «Энергетика». – 2016. – Т. 16, № 2. – С. 59-65. – DOI: 10.14529/power160208.
9. *Кудрин Б.И., Мозгалин А.В.* Методика обеспечения почасового прогнозирования электропотребления предприятий с учетом погодных факторов // Вестник МЭИ. – 2007. – № 2. – С. 45-47.
10. Патент 115098 РФ: МПК G06N 5/00. Многослойная нейронная сеть / Белов К.Д.; заявитель и патентообладатель: Белов К.Д. – №2011139784/08; заявл. 29.09.2011; опубл. 20.04.2012, Бюл. № 11.
11. Патент 169425 РФ: МПК G06Q 10/06, G06N 5/00. Устройство прогнозирования электропотребления на основе многослойной нейронной сети / Хамитов Р.Н.; заявитель и патентообладатель: ФБГОУ ВО Омский государственный технический университет – 2016145339; заявл. 18.11.2016; опубл. 17.03.2016.
12. Патент 222420 РФ: МПК G06N 5/00, G06Q 10/06. Устройство мониторинга и прогнозирования электропотребления в электроэнергетических системах на основе нейронных структур / Качелаев О.В., Полуянович Н.К., Дубяго М.Н.; патентообладатель: Южный федеральный университет. 2023126166; заявл. 12 октября 2023; опубл. 25 декабря 2023 г.
13. *Сивак М.А., Тимофеев В.С.* Построение робастных нейронных сетей с различными функциями потерь // Системы анализа и обработки данных. – 2021. – № 2 (82). – С. 67-82. – DOI: 10.17212/2782-2001-2021-2-67-82.
14. *Haykin S.* Neural Networks and Learning Machines. – 3rd ed. – Pearson Education, 2009. – 906 p.
15. *Bishop C.M.* Neural Networks for Pattern Recognition. – New York, US: Oxford University Press, 1995. – 502 p.
16. *Brownlee J.* A Gentle Introduction to the Rectified Linear Unit (ReLU). – 2019. – URL: <https://inlnk.ru/agw2E2> (visited on 02/19/2022).
17. GeeksforGeeks A computer science portal for geeks. – URL: <https://www.geeksforgeeks.org/regression-metrics/>.
18. *Сивак М.А.* Робастное обучение нейронных сетей с простой архитектурой для решения задач классификации: дисс. ... канд. наук: 05.13.17. – Новосибирск: НГТУ, 2022. – 111 с.
19. *Дубяго М.Н., Полуянович Н.К.* Совершенствование методов диагностики и прогнозирования электроизоляционных материалов систем энергоснабжения: монография. – Ростов-на-Дону; Таганрог: Изд-во ЮФУ, 2019. – 192 с.

20. *Полуянович Н.К., Бурьков Д.В., Дубяго М.Н.* Нейросетевой метод прогнозирования электропотребления и его инструментальная реализация: монография. – Ростов-на-Дону; Таганрог: Изд-во ЮФУ, 2023. – 151 с.
21. *Пальчевский Е.В.* Методы нейросетевой обработки больших темпоральных данных для информационной поддержки принятия управленческих решений (на примере электроэнергетики): дисс. ... канд. техн. наук: 2.3.1.. – Уфа: Уфимский университет науки и технологий, 2024.

REFERENCES

1. Postanovlenie Pravitel'stva RF ot 9 sentyabrya 2023 g. N 1473 "Ob utverzhdenii kompleksnoy gosudarstvennoy programmy Rossiyskoy Federatsii "Energoberezhenie i povyshenie energeticheskoy effektivnosti" [Resolution of the Government of the Russian Federation of September 9, 2023 N 1473 "On approval of the comprehensive state program of the Russian Federation "Energy saving and increasing energy efficiency"], *Razmeshchen v SPS "Konsul'tant Plyus"* [Posted in the SPS "Consultant Plus"]. Available at: <https://base.garant.ru/407632842/>.
2. *Poluyanovich N.K.* Montazh, naladka, ekspluatatsiya i remont sistem elektrosnabzheniya promyshlennykh predpriyatij. Ser. uchebniki dlya vuzov. Spetsial'naya literature [Installation, adjustment, operation and repair of power supply systems of industrial enterprises. Series of textbooks for universities. Special literature]. 3rd ed. Saint Petersburg, 2017.
3. *Rodygina S.V.* Proektirovanie i ekspluatatsiya sistem elektrosnabzheniya. Peredacha, raspredelenie, preobrazovanie elektricheskoy energii: ucheb. posobie [Design and operation of power supply systems. Transmission, distribution, transformation of electrical energy: a textbook]. Novosibirsk: Izd-vo NGTU, 2017, 72 p.
4. *Serebryakov N.A., Khomutov S.O.* Analiz sluchaynoy sostavlyayushchey vremennogo ryada elektricheskoy nagruzki gruppy toчек postavki elektroenergii sel'khozproizvoditeley [Analysis of the random component of the time series of the electric load of a group of electricity supply points of agricultural producers], *Vestnik Altayskogo gosudarstvennogo agrarnogo universiteta* [Bulletin of the Altai State Agrarian University], 2019, No. 5 (175), pp. 153-158.
5. *Poluyanovich N.K., Dubyago M.N.* Otsenka vozdeystvuyushchikh faktorov i prognozirovanie elektropotrebleniya v regional'noy energosisteme s uchetoм rezhima ee ekspluatatsii [Assessment of influencing factors and forecasting of electricity consumption in the regional energy system, taking into account its operating mode], *Izvestiya YuFU. Tekhnicheskie nauki* [Izvestiya SFedU. Engineering Sciences], 2022, No. 2 (226), pp. 31-46.
6. *Rudakov E., Saakyan Yu., Nigmatulin B., Prokhorova N.* Tsena rastochitel'nosti [The Price of Waste-fulness], *Ekspert* [Expert], Iyun' 2008, No. 24.
7. *Bilalova A.I.* Statistika potrebleniya elektroenergii v g. Ul'yanovsk [Statistics of Electricity Consumption in Ulyanovsk], *Vuzovskaya nauka v sovremennykh usloviyakh: Sb. materialov 48-y nauchno-tekhnicheskoy konferentsii* [University Science in Modern Conditions: Collection of Materials of the 48th Scientific and Technical Conference]. Ul'yanovsk: UIGTU, 2013, pp. 15-18.
8. *Domanov V.I., Bilalova A.I.* Prognozirovanie ob'emov energopotrebleniya v zavisimosti ot iskhodnoy informatsii [Forecasting energy consumption volumes depending on the initial information], *Vestnik YuUrGU. Seriya «Energetika»* [Bulletin of SUSU. Series "Power Engineering"], 2016, Vol. 16, No. 2, pp. 59-65. DOI: 10.14529/power160208.
9. *Kudrin B.I., Mozgalin A.V.* Metodika obespecheniya pochasovogo prognozirovaniya elektropotrebleniya predpriyatij s uchetoм pogodnykh faktorov [Methodology for ensuring hourly forecasting of electricity consumption of enterprises taking into account weather factors], *Vestnik MEI* [Bulletin of MPEI], 2007, No. 2, pp. 45-47.
10. *Belov K.D.* Patent 115098 RF: MPK G06N 5/00. Mnogosloynaya neyronnaya set' [Patent 115098 of the Russian Federation: IPC G06N 5/00. Multilayer neural network]; applicant and patent holder: Belov K.D. – No. 2011139784/08; declared 29.09.2011; published 20.04.2012, Bulletin No. 11.
11. *Khamitov R.N.* Patent 169425 RF: MPK G06Q 10/06, G06N 5/00. Ustroystvo prognozirovaniya elektropotrebleniya na osnove mnogoslnoynoy neyronnoy seti [Patent 169425 of the Russian Federation: IPC G06Q 10/06, G06N 5/00. Device for predicting electricity consumption based on a multilayer neural network]; applicant and patent holder: Omsk State Technical University – 2016145339; declared 18.11.2016; published 17.03.2016.
12. *Kachelaev O.V., Poluyanovich N.K., Dubyago M.N.* Patent 222420 RF: MPK G06N 5/00, G06Q 10/06. Ustroystvo monitoringa i prognozirovaniya elektropotrebleniya v elektroenergeticheskikh sistemakh na osnove neyronnykh struktur [Patent 222420 of the Russian Federation: IPC G06N 5/00, G06Q 10/06. Device for monitoring and forecasting electricity consumption in electric power systems based on neural structures]; patent holder: Southern Federal University. 2023126166; declared October 12, 2023; published December 25, 2023.

13. *Sivak M.A., Timofeev V.S.* Postroenie robastnykh neyronnykh setey s razlichnymi funktsiyami poter' [Construction of robust neural networks with different loss functions], *Sistemy analiza i obrabotki dannykh* [Systems of data analysis and processing], 2021, No. 2 (82), pp. 67-82. DOI: 10.17212/2782-2001-2021-2-67-82.
14. *Haykin S.* Neural Networks and Learning Machines. 3rd ed. Pearson Education, 2009, 906 p.
15. *Bishop C.M.* Neural Networks for Pattern Recognition. New York, US: Oxford University Press, 1995, 502 p.
16. *Brownlee J.* A Gentle Introduction to the Rectified Linear Unit (ReLU), 2019. Available at: <https://inlnk.ru/agw2E2> (visited on 02/19/2022).
17. GeeksforGeeks A computer science portal for geeks. Available at: <https://www.geeksforgeeks.org/regression-metrics/>.
18. *Sivak M.A.* Robastnoe obuchenie neyronnykh setey s prostoy arkhitekturoy dlya resheniya zadach klassifikatsii: diss. ... kand. Nauk [Robust training of neural networks with simple architecture for solving classification problems: cand. of eng. sc. diss.]: 05.13.17. Novosibirsk: NGTU, 2022, 111 s.
19. *Dubyago M.N., Poluyanovich N.K.* Sovershenstvovanie metodov diagnostiki i prognozirovaniya elektroizolyatsionnykh materialov sistem energosnabzheniya: monografiya [Improving methods for diagnostics and forecasting of electrical insulating materials of power supply systems: monograph]. Rostov-on-Don; Taganrog: Izd-vo YuFU, 2019, 192 p.
20. *Poluyanovich N.K., Bur'kov D.V., Dubyago M.N.* Neyrosetevoy metod prognozirovaniya elektropotrebleniya i ego instrumental'naya realizatsiya: monografiya [Neural network method for forecasting electricity consumption and its instrumental implementation: monograph]. Rostov-on-Don; Taganrog: Izd-vo YuFU, 2023, 151 p.
21. *Pal'chevskiy E.V.* Metody neyrosetevoy obrabotki bol'shikh temporal'nykh dannykh dlya informatsionnoy podderzhki prinyatiya upravlencheskikh resheniy (na primere elektroenergetiki): diss. ... kand. tekhn. nauk [Methods of neural network processing of big temporal data for information support of management decisions (on the example of the electric power industry): cand. of eng. sc. diss.]: 2.3.1. Ufa: Ufimskiy universitet nauki i tekhnologii, 2024.

Полуянович Николай Константинович – Южный федеральный университет; e-mail: nik1-58@mail.ru; г. Таганрог, Россия; тел.: 89185693365; кафедра электротехники и мехатроники; к.т.н.; доцент.

Качелаев Олег Вадимович. – Южный федеральный университет; e-mail: 22.olezhka@mail.ru; г. Таганрог, Россия; тел.: 89281163960; кафедра техносферной безопасности и химии; аспирант.

Дубяго Марина Николаевна – Южный федеральный университет; e-mail: w_m88@mail.ru; тел.: 89281758225; кафедра электротехники и мехатроники; к.т.н.; доцент.

Poluyanovich Nikolay Konstantinovich – Southern Federal University; e-mail: nik1-58@mail.ru; Taganrog, Russia; phone: +79185693365; the Department of Electric Technics and Mechatronics; cand. of eng. sc.; associate professor.

Kachelaev Oleg Vadimovich – Southern Federal University; e-mail: 22.olezhka@mail.ru; Taganrog, Russia; phone: +79281163960; the Department of Techno-sphere Safety and Chemistry; postgraduate student.

Dubyago Marina Nikolaevna – Southern Federal University; e-mail: w_m88@mail.ru; phone: +79281758225; Taganrog, Russia; the Department of Electrical Engineering and Mechatronics; cand. of eng. sc.; associate professor.

УДК 004.8

DOI 10.18522/2311-3103-2025-1-118-129

А.Н. Целых, И.А. Валухов, Л.А. Целых

ИЗВЛЕЧЕНИЕ ПРИЧИННО-СЛЕДСТВЕННЫХ КОРТЕЖЕЙ ИЗ ТЕКСТА НА ОСНОВЕ ГЛУБОКОГО ОБУЧЕНИЯ С ИСПОЛЬЗОВАНИЕМ СИНТЕТИЧЕСКИХ ДАННЫХ

Рассматривается проблема разработки модели извлечения полных причинных кортежей из неструктурированных текстов для представления ситуаций принятых решений в сложных социогуманитарных средах. Совокупность извлекаемых кортежей из определенного набора текстов представляет собой связанные сущности конкретной среды, что позволяет создать причинно-следственные графы. В этой статье предлагается модель извлечения причинно-следственных