

Электронный научный журнал «Век качества» ISSN 2500-1841 <https://www.agequal.ru>

2026, №2 https://www.agequal.ru/pdf/2026/AGE_QUALITY_2_2026.pdf

Ссылка для цитирования этой статьи:

Шувалов В.П., Будылдина Н.В., Юрченко Е.В. Оценка надежности шлюза сети интернета вещей на основе результатов прогнозирования его энергопотребления // Электронный научный журнал «Век качества». 2026. №2. С. 311-329. Режим доступа: <https://www.agequal.ru/pdf/2026/226020.pdf> (доступ свободный). Загл. с экрана. Яз. рус., англ.

УДК 004

**Оценка надежности шлюза сети интернета вещей на основе
результатов прогнозирования его энергопотребления**

Шувалов Вячеслав Петрович,
профессор, доктор технических наук,
Федеральное государственное бюджетное
образовательное учреждение высшего образования
«Сибирский государственный университет
телекоммуникаций и информатики» (СибГУТИ),
Новосибирск, Россия
shvp04@mail.ru

Будылдина Надежда Вениаминовна,
доцент, кандидат технических наук,
Уральский технический институт связи и информатики (филиал)
Федерального государственного бюджетного образовательного учреждения
высшего образования «Сибирский государственный университет
телекоммуникаций и информатики» в г. Екатеринбурге (УрТИСИ СибГУТИ),
Екатеринбург, Россия
20bnv@mail.ru

Юрченко Евгения Владимировна,
старший преподаватель,
Уральский технический институт связи и информатики (филиал)
Федерального государственного бюджетного образовательного учреждения
высшего образования «Сибирский государственный университет
телекоммуникаций и информатики» в г. Екатеринбурге (УрТИСИ СибГУТИ),
Екатеринбург, Россия
jena23@mail.ru

Применение искусственных нейронных сетей (ИНС) для решения задач в сфере электроснабжения сетей интернета вещей, становится все более актуальным. В работе рассматривается использование рекуррентной нейронной

сети с долговременной краткосрочной памятью для прогнозирования энергопотребления шлюза сети интернета вещей. В качестве входных параметров для обучения ИНС использовались значения общего энергопотребления и объёма переданного через шлюз трафика для различных интервалов опроса датчиков. ИНС была обучена для данных, полученных с использованием линейного алгоритма оптимизации энергопотребления шлюза и данных сети интернета вещей, полученных экспериментальным путем. В качестве шлюза сети ИВ использовался мобильный телефон с ограниченными энергоресурсами, при выходе из строя которого сеть становится неработоспособной. Оконечными устройствами являются датчики расстояния, температуры, влажности и атмосферного давления. Определено время автономной работы шлюза (примерно 39 ч). Для оценки надежности шлюза использован математический аппарат марковских процессов. Расчеты показали высокую краткосрочную надежность работы шлюза (99,7% за 39 ч).

Ключевые слова: Интернет вещей; оптимизация; энергопотребление; рекуррентная нейронная сеть; марковские процессы.

Введение

Современный уровень развития технологий интернета вещей (ИВ) открывает новые возможности для создания интеллектуальных систем, способных автоматически собирать, обрабатывать и анализировать данные в реальном масштабе времени. Однако широкое внедрение сетей ИВ сталкивается с рядом проблем, одной из которых является обеспечение энергоэффективности и надежности работы сетевых компонентов, особенно в условиях их автономной работы. Важным сетевым компонентом сети ИВ является шлюз – устройство, которое обеспечивает взаимодействие между датчиками, сервером и облачными сервисами.

Энергопотребление шлюза зависит от множества факторов: количества подключенных датчиков, частоты опроса, объема передаваемых данных, а также применяемых алгоритмов обработки информации. Для прогнозирования энергозатрат и оптимизации работы системы в работе предлагается использование рекуррентной нейронной сети (РНС) с долговременной краткосрочной памятью (LSTM – Long short-term memory), которая способна

эффективно работать с временными рядами и учитывать динамические изменения параметров системы [1].

Нейросетевые подходы обладают рядом преимуществ, включая способность обрабатывать большие объемы сложных данных, адаптацию к изменяющимся условиям и высокую точность прогнозирования. В работах [2-10] исследуются различные методы нейросетевого моделирования для оптимизации энергопотребления в сетях ИВ. Так, в [2] рассматриваются комбинированные подходы, включая машинное обучение, метаэвристические алгоритмы и нечеткие логические системы, направленные на снижение энергозатрат, минимизацию потерь и повышение кибербезопасности. В работах [3, 4] предложены алгоритмы оптимизации энергопотребления для умных городских систем на основе ИВ. В [5] представлен нейросетевой алгоритм прогнозирования энергопотребления промышленного предприятия, учитывающий такие факторы, как время работы, среднемесячная температура и исторические данные по энергозатратам. Особое внимание в литературе уделяется РНС, в частности методу LSTM, который демонстрирует высокую эффективность в задачах временного прогнозирования [6, 7]. В [8] предложена гибридная модель на основе нечеткой логики и обратного распространения ошибки, а в [9] прогнозирование энергопотребления осуществляется с учетом поведенческих факторов пользователей. В [10] применяется классическая нейронная сеть с обратным распространением ошибки для прогноза энергопотребления на основе данных о температуре и мощности.

Следует отметить значительное количество исследований, посвященных прогнозированию энергопотребления в сетях ИВ. Однако в основном они направлены на исследование энергопотребления оконечных устройств и системы в целом. Вопрос энергопотребления шлюза сети ИВ остается недостаточно изученным. Для прогнозирования энергопотребления шлюза сети ИВ будут использоваться данные для обучения сети LSTM, полученные с использованием линейного алгоритма оптимизации [11] и данных, полученных

экспериментальным путем. За счет этого возрастает объем входных данных, что повышает точность прогнозирования.

Для оценки надежности работы шлюза применяется математический аппарат марковских процессов, позволяющий смоделировать различные состояния шлюза сети (работоспособное, зависание телефона, аккумулятор разряжен, аккумулятор на подзарядке). Это дает возможность не только прогнозировать время наработки на отказ, но и выявлять критические точки работы шлюза сети ИВ, что необходимо для разработки мер по повышению её надежности.

Таким образом, цель данной работы заключается в разработке комплексного подхода к оптимизации и прогнозированию энергопотребления шлюза сети ИВ с помощью РНС LSTM и оценке надежности на основе математического аппарата марковских процессов. Результаты работы могут быть применены при проектировании энергоэффективных и отказоустойчивых сетей ИВ.

Реализация нейронной сети

Для создания нейронной сети требуется задать значения входных данных, которые разделены на два блока. Элементы первого блока данных рассчитываются с использованием линейного алгоритма определения оптимального времени опроса датчиков сети [11]. Элементы второго блока содержат экспериментальные данные, полученные путем замеров энергопотребления шлюза сети ИВ. Таким образом, расширяется матрица входных данных для точного обучения. Для определения оптимального времени опроса датчиков используется линейный алгоритм. Расчет данных осуществляется для трех датчиков. Начальное время между опросами $T_{opros} = 15c$, общее время работы системы $T = 7200c$, емкость аккумулятора $E_{vix} = 5000мА$ (рис. 1).

Генерация датасета и обучение модели

Максимальное количество датчиков:

T (сек):

Торгов (сек):

Е_{вих} (мА):

m (шаги):

Рис. 1. Входные данные для линейного алгоритма определения оптимального времени между опросами датчиков сети

После получения рассчитанных данных формируется датасет с учетом экспериментальных данных. На рис. 2 показан фрагмент матрицы входных данных V .

	I	C	H	P	E
0	0.0	1.0	15.0	22285.0	295.5975
1	0.0	1.0	30.0	12205.0	260.3175
2	0.0	1.0	60.0	7165.0	242.6775
3	0.0	1.0	120.0	4645.0	233.8575
4	0.0	1.0	240.0	3385.0	229.4475
5	0.0	1.0	480.0	2755.0	227.2425
6	1.0	1.0	15.0	12885.6	262.6512
7	1.0	1.0	30.0	6655.2	250.1904
8	1.0	1.0	60.0	4106.4	245.0928
9	1.0	1.0	120.0	2548.8	241.9776
10	0.0	2.0	15.0	32845.0	332.5575
11	0.0	2.0	30.0	17485.0	278.7975

Рис. 2. Фрагмент матрицы входных данных

Входные данные учитывают:

- 1) два режима работы сети ИВ, с прерыванием работы на время бездействия шлюза и без прерывания (1.0 и 0.0);
- 2) индекс датчика (устройства) C , где диапазон равен от 1 до 3;
- 3) время опроса датчика (устройства) H (15 с, 30 с, 60 с, 120 с, 240 с, 480 с, 960 с);
- 4) трафик, переданный по сети через шлюз, P ;
- 5) общее энергопотребление, $E_{вых(общ)}$.

В процессе обучения модель работает с двумя наборами данных: тренировочным и тестовым. Тренировочный набор, составляющий 80% от общего объема данных, используется для настройки параметров сети. Оставшиеся 20% образуют тестовый набор, который позволяет оценить качество работы модели на новых, ранее не встречавшихся данных.

Каждый набор данных дополнительно структурируется на данные:

- которые подаются на вход нейронной сети;
- и целевые значения, которые модель должна предсказать.

Поскольку нейронные сети эффективно обрабатывают числовые массивы, исходные табличные данные нужно преобразовать в матричный формат. Это обеспечивает корректную работу алгоритмов машинного обучения и ускоряет вычислительные процессы.

Обучение проводилось в течение 1000 эпох, что позволило модели постепенно минимизировать ошибку прогнозирования. На рис. 3 представлена динамика изменения функции потерь в процессе обучения, демонстрирующая сходимость алгоритма.

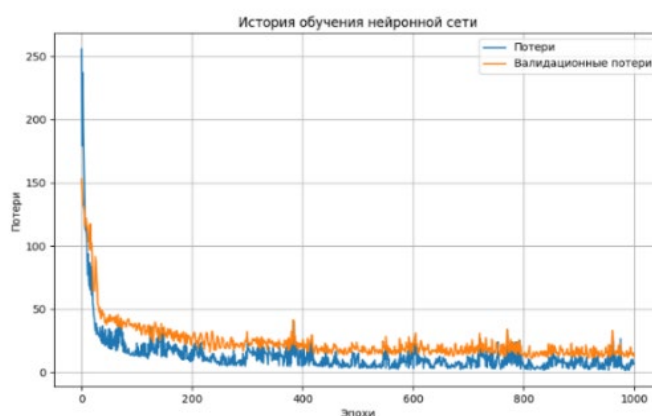


Рис. 3. Обучение нейронной сети

График отображает потери на тренировочных данных и валидационные потери. Ось x соответствует количеству эпох (от 0 до 1000), а ось y – величине потерь (от 0 до 200).

Тренировочные потери – это потери, которые показывают, насколько хорошо модель обучается на тренировочных данных. На графике видно, что потери резко снижаются в начале обучения (первые 200 эпох), а затем продолжают уменьшаться, но более плавно.

Валидационные потери – это метрика, которая оценивает качество обучения модели на данных, не участвовавших в обучении. Здесь также наблюдается снижение потерь, но после определенного момента (примерно на 600 эпохе) они могут начать расти или стабилизироваться, что указывает на возможное переобучение.

На рис. 4 представлен график, позволяющий сравнить фактические значения энергопотребления с прогнозируемыми. Ось x соответствует номерам образцов (наблюдений), а ось y – уровню энергопотребления от 0 до 310 мА.


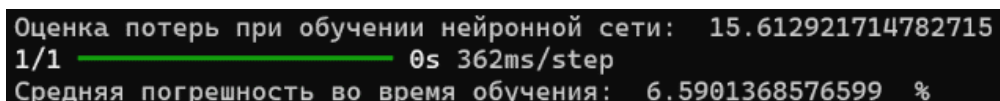


Рис. 4. График сравнения фактических значений и прогнозов

Фактические значения – это данные, полученные с помощью линейного алгоритма оптимизации и экспериментальным путем. Они служат эталоном для оценки точности модели. Прогнозы – это значения, предсказанные моделью на основе входных данных. Сравнение прогнозов с фактическими значениями позволяет оценить качество работы модели. На некоторых участках прогнозы

почти совпадают с фактическими значениями, что говорит о правильной работе модели в этих диапазонах, расхождения не критичны.

После обучения RHC LSTM сеть была протестирована на финальную точность с использованием неизвестных для нейронной сети данных. В качестве неизвестных данных использовалась тестовая выборка данных (рис. 5).

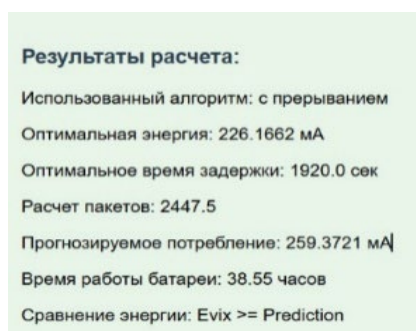


```
Оценка потерь при обучении нейронной сети: 15.612921714782715  
1/1 ██████████ 0s 362ms/step  
Средняя погрешность во время обучения: 6.5901368576599 %
```

Рис. 5. Тестирование нейронной сети

С учетом того, что целевая переменная имеет диапазон значений до 300 мА, анализ результатов обучения нейронной сети с метрикой MAE позволяет сделать следующие выводы. Значение средней абсолютной ошибки (MAE) в 15,61 единицы на последней эпохе и 6,59% в среднем за обучение позволяет говорить о хорошей оценке. В абсолютном выражении модель в среднем ошибается на 15,61 единиц от фактического значения. В процентном отношении средняя ошибка составляет около 6,59% от диапазона данных.

После обучения RHC LSTM можно рассчитать автономное время работы шлюза сети ИВ с учетом емкости аккумулятора телефона (рис. 6).



```
Результаты расчета:  
Использованный алгоритм: с прерыванием  
Оптимальная энергия: 226.1662 мА  
Оптимальное время задержки: 1920.0 сек  
Расчет пакетов: 2447.5  
Прогнозируемое потребление: 259.3721 мА  
Время работы батареи: 38.55 часов  
Сравнение энергии: Evis >= Prediction
```

Рис. 6. Результаты расчета автономного времени работы шлюза

Исходя из расчетов, потребление в активном режиме составляет 226,16 мА с периодом опроса датчиков (задержкой) 1920 с. Это означает, что устройство свыше 94% времени проводит в режиме с низким энергопотреблением, сокращая общий расход заряда батареи.

Расчетное время работы батареи шлюза составило 38,55 ч, что можно считать приемлемым для многих применений. Однако если требуется длительная автономная работа в несколько дней или недель, данное значение следует считать недостаточным. Для дальнейшего улучшения этого показателя необходимо либо увеличить время между опросами датчиков, либо использовать аккумулятор с большей емкостью.

Таким образом разработанная РНС LSTM позволяет оптимизировать и спрогнозировать энергопотребление шлюза сети ИВ, определить автономное время работы шлюза сети ИВ. Знание времени работы шлюза позволяет своевременно выполнить подзарядку или замену аккумулятора до того, как сеть ИВ выйдет из строя, и тем самым повысить ее надежность.

Расчет показателей надежности шлюза сети ИВ

Расчет показателей надежности выполнен на основе спрогнозированного общего времени работы шлюза сети ИВ. Согласно расчетам, общее время работы для аккумуляторной батареи емкостью 5000 мА составило 38,55 ч (для удобства округлим до 39 ч). Для количественной оценки надежности системы используем математический аппарат марковских процессов [12].

Шлюз сети может находиться в четырех состояниях: работоспособном, зависание телефона, аккумулятор разряжен, аккумулятор на подзарядке.

Работоспособное состояние (исправность) – состояние объекта, в котором он соответствует всем требованиям, установленным на него в документации. Предотказное состояние (подзарядка) – состояние объекта, характеризующееся повышенным риском его отказа. Неисправное состояние или отказ (зависание телефона, аккумулятор разряжен) – состояние объекта, в котором он не

соответствует хотя бы одному из требований, установленных на него в документации [13]. Возможны переходы из работоспособного состояния в предотказное состояние или из предотказного в отказ. Возможно восстановление работоспособного состояния из предотказного состояния и из состояния отказа.

Граф состояний для расчета показателей надежности работы шлюза приведен на рис. 7:




Рис. 7. Граф состояний-переходов описываемой модели

На рис. 7 обозначено:

S_1 – работоспособное состояние;

S_2 – зависание телефона (состояние отказа);

S_3 – аккумулятор телефона разряжен (состояние отказа);

S_4 – аккумулятор телефона в стадии подзарядки (состояние предотказа);

λ_{12} – интенсивность перехода из работоспособного состояния в отказ;

λ_{13} – интенсивность перехода из работоспособного состояния в отказ;

λ_{14} – интенсивность перехода из работоспособного состояния в предотказное;

μ_{21} – интенсивность перехода из отказа в работоспособное состояние;

μ_{34} – интенсивность перехода из отказа в предотказное состояние;

λ_{42} – интенсивность перехода из предотказного состояния в отказ;

μ_{41} – интенсивность перехода из предотказного состояния в работоспособное.

Составим матрицу интенсивностей переходов шлюза из состояния i в состояние j :

$$\Lambda = \begin{pmatrix} -(\lambda_{12} + \lambda_{13} + \lambda_{14}) & \lambda_{12} & \lambda_{13} & \lambda_{14} \\ \mu_{21} & -\mu_{21} & 0 & 0 \\ 0 & 0 & -\mu_{34} & \mu_{34} \\ \mu_{41} & \lambda_{42} & 0 & -(\mu_{41} + \lambda_{42}) \end{pmatrix} \quad (1)$$

Система дифференциальных уравнений запишется в виде:

$$\begin{cases} \frac{dp_1(t)}{dt} = \mu_{21}p_2(t) + \mu_{41}p_4(t) - \lambda_{13}p_1 - \lambda_{14}p_1 \\ \frac{dp_2(t)}{dt} = \lambda_{12}p_1 + \lambda_{42}p_4(t) - \mu_{21}p_2(t) \\ \frac{dp_3(t)}{dt} = \lambda_{13}p_1 - \mu_{34}p_3(t) \\ \frac{dp_4(t)}{dt} = \lambda_{14}p_1 + \mu_{34}p_3(t) - \mu_{41}p_4(t) - \lambda_{42}p_4(t) \end{cases} \quad (2)$$

Рассмотрим установившейся режим, когда $\frac{dp_i(t)}{dt} = 0$. Тогда для установившегося режима суммарный поток вероятности, переводящий систему в состояние S_j из других состояний, равен суммарному потоку вероятности, выводящему систему из состояния S_j , который можно определить [14]:

$$\sum_{\substack{i=1 \\ (i \neq j)}}^n p_i \lambda_{ij} = p_j \sum_{\substack{i=1 \\ (i \neq j)}}^n \lambda_{ij} \quad (j=1, 2, \dots, n) \quad (3)$$

Условие нормировки будет выглядеть:

$$\sum_{i=1}^n p_j = 1 \quad (4)$$

$$\begin{cases} \mu_{21}P_2 + \mu_{41}P_4 - \lambda_{13}P_1 - \lambda_{12}P_1 - \lambda_{14}P_1 = 0 \\ \lambda_{12}P_1 + \lambda_{42}P_4 - \mu_{21}P_2 = 0 \\ \lambda_{13}P_1 - \mu_{34}P_3 = 0 \\ \lambda_{14}P_1 + \mu_{34}P_3 - \mu_{41}P_4 - \lambda_{42}P_4 = 0 \end{cases}, \quad (5)$$

Решив систему линейных уравнений с учетом нормировочного условия, найдем вероятности всех состояний шлюза сети ИВ:

$$P_3 = \frac{\lambda_{13}}{\mu_{34}} P_1, \quad (6)$$

$$P_4 = \frac{\lambda_{14} + \lambda_{13}}{\mu_{41} + \lambda_{42}} P_1, \quad (7)$$

$$P_2 = \frac{\lambda_{12} + \frac{\lambda_{42} \times (\lambda_{14} + \lambda_{13})}{\mu_{41} + \lambda_{42}}}{\mu_{21}} P_1, \quad (8)$$

$$P_1 = \frac{1}{1 + \frac{\lambda_{12} + \frac{\lambda_{42} \times (\lambda_{14} + \lambda_{13})}{\mu_{41} + \lambda_{42}}}{\mu_{21}} + \frac{\lambda_{13}}{\mu_{34}} + \frac{\lambda_{14} + \lambda_{13}}{\mu_{41} + \lambda_{42}}}. \quad (9)$$

Коэффициент готовности шлюза сети ИВ можно определить как:

$$K_{ГС} = P_1 + P_4. \quad (10)$$

Примем следующие значения для интенсивностей восстановления и отказов:

– время перехода из предотказа в отказ является случайной величиной и может произойти в любой момент времени, время перехода из предотказа в отказ: $T_{no}(ч)$;

– время восстановления из предотказа в работоспособное состояние состоит из времени подзарядки аккумулятора, то есть устранения предотказа: $T_{ep} = 2(ч)$, $\mu_{41} = 0,5ч^{-1}$;

– время восстановления из отказа в работоспособное состояние определяется временем обнаружения отказа, время до начала подзарядки телефона и его подзарядки: $T_{ог}(ч)$;

– время работоспособного состояния $T_p = 39(ч)$:

Рассчитаем показатели для $\lambda_{42} = 0,01$ (вероятность перехода из состояния подзарядки в состояние зависания крайне мала), возьмем время перехода из состояния зависания телефона в работоспособное равным $0,05$ ч. Отсюда $\mu_{21} = 20ч^{-1}$.

Так как время работоспособного состояния шлюза сети ИВ, спрогнозированного РНС, составляет 39 ч, то:

$$\lambda_{12} + \lambda_{13} + \lambda_{14} = \frac{1}{T_p} = \frac{1}{39}ч^{-1}.$$

Предположим, что λ_{12} будет мало и будет равняться 5% , λ_{14} будет самым большим, так как, согласно прогнозированию, можно предотвратить состояние отказа, и будет равно 90% , 5% заложим на λ_{13} на случай, когда телефон не будет поставлен вовремя на подзарядку, тогда:

$$\hat{\lambda}_{sum} = \frac{1}{39} \approx 0,025641, \lambda_{12} \approx 0,00128205, \lambda_{13} \approx 0,00128205, \lambda_{14} \approx 0,0230769.$$

Вероятность p_3 – это доля времени в состоянии 3 (отказ типа «разрядился»). В реальности для телефона состояние 3 («разрядился») – это тоже отказ, но переход из него возможен только через предотказ (состояние s_4) с интенсивностью μ_{34} . Однако в установившемся режиме поток из s_3 в s_4 равен потоку из s_1 в s_3 .

Если λ_{34} не задана, то её можно найти, если известно, например, среднее время перехода из s_3 в s_4 . Допустим, время перехода из «разрядился» в «предотказ» (когда телефон подключили к зарядке) – 2 ч, тогда $\mu_{34} = \frac{1}{2} = 0,5ч^{-1}$.

Рассчитаем по (6)-(10) вероятности для всех состояний шлюза сети ИВ при установившемся режиме: $P_1 = 0,952005$, $P_3 = 0,00244104$, $P_4 = 0,0454702$, $P_2 = 0,000083761$, $K_{ГС} = P_1 + P_4 = 0,9974752$.

В результате выполненного расчёта установлено, что при установившемся режиме вероятность работоспособного состояния составляет

0,952, а при учете предотказного состояния как условно рабочего – 0,997, что свидетельствует о высокой потенциальной надёжности шлюза при своевременной подзарядке аккумулятора телефона. Полученные результаты могут использоваться для оптимизации периодичности подзарядки аккумулятора телефона и оценки времени безотказной работы шлюза ИВ.

Заключение

Проведенное исследование было направлено на решение актуальной задачи повышения энергоэффективности и надежности шлюза в экспериментальной сети интернета вещей. Был разработан и апробирован комплексный подход, сочетающий алгоритмическую оптимизацию, прогнозное моделирование и вероятностную оценку надежности.

Обученная модель продемонстрировала хорошую точность со средней абсолютной ошибкой (MAE) в 15,61 единицы (6,59%), что является удовлетворительным результатом для практического применения.

Для количественной оценки надежности системы был использован математический аппарат марковских процессов, учитывающий состояния шлюза: работоспособное, зависание телефона, аккумулятор разряжен, аккумулятор на подзарядке. Расчеты показали, что система обладает высокой краткосрочной надежностью – 99,7% для работоспособного состояния за 39 ч работы.

Разработанный подход позволяет на этапе проектирования сети ИВ спрогнозировать энергопотребление и время автономной работы при изменении конфигурации сети (добавлении новых датчиков, изменении частоты опроса); оценить и повысить надежность сети путем анализа слабых мест и моделирования эффекта от предложенных улучшений (например, увеличения вероятности своевременной зарядки или улучшения алгоритмов восстановления); планировать мероприятия по техническому обслуживанию

(например, периодичность подзарядки) для предотвращения критических отказов.

Список литературы

1. Вакуленко, С.А. Нейронные сети : учебное пособие / С.А. Вакуленко, А.А. Жихарева. – Санкт-Петербург: Санкт-Петербургский государственный университет промышленных технологий и дизайна, 2019. – 110 с. – DOI 10.23682/102447.
2. Михайлов, А.Н. Применение алгоритмов искусственного интеллекта в энергетическом секторе / А.Н. Михайлов, Г.В. Савостина // Молодежь и наука-2023 : материалы международной научно-практической конференции, Петропавловск, 12 апреля 2023 г. – Петропавловск: Некоммерческое акционерное общество «Северо-Казахстанский университет имени Манаша Козыбаева», 2023. – С. 276-280.
3. Кутуев, И.В. Системный анализ, методы и алгоритмы принятия решений по повышению энергоэффективности населенного пункта / И.В. Кутуев, Д.А. Федоров, К.И. Бушмелева // ВК. – 2020. – № 1 (37). – URL: <https://cyberleninka.ru/article/n/sistemnyy-analiz-metody-i-algoritmy-prinyatiya-resheniy-po-povysheniyu-energoeffektivnosti-naselennogo-punkta> (дата обращения: 11.11.2025).
4. Кассем, С.А. Прогнозирование электропотребления предприятия с применением искусственных нейронных сетей / С.А. Кассем, А.Х.А. Ибрагим, А.М. Хасан, А.Г. Логачева // Вестник Тюменского государственного университета. Физико-математическое моделирование. Нефть, газ, энергетика. – 2021. – Том 7. – № 1 (25). – С. 177-193. – DOI 10.21684/2411-7978-2021-7-1-177-193.
5. Таранов, Р.В. Прогнозирование энергопотребления при помощи искусственных нейронных сетей с применением технологии cuda / Р.В. Таранов, А.В. Маликов // Вестник АГТУ. Серия: Управление,

- вычислительная техника и информатика. – 2016. – № 3. – URL: <https://cyberleninka.ru/article/n/prognozirovanie-energopotrebleniya-pri-pomoschi-iskusstvennyh-neyronnyh-setey-s-primeneniem-tehnologii-cuda> (дата обращения: 06.12.2025).
6. Рахмонов, И.У. Прогнозирование электропотребления с помощью нейронных сетей с LSTM / И.У. Рахмонов, В.Я. Ушаков, Н.Н. Ниезов, Н.Н. Курбонов // Известия Томского политехнического университета. Инжиниринг георесурсов. – 2023. – Т. 334, № 12. – С. 125-133. – DOI 10.18799/24131830/2023/12/4407.
 7. Вялкова, С.А. Применение нейронных сетей для прогнозирования электропотребления мегаполиса / С.А. Вялкова, И.И. Надтока, О.А. Корнюкова // Машиностроение: сетевой электронный научный журнал. – 2023. – Т. 10. – № 4. – С. 12-16. – DOI 10.24892/RIJE/20230403.
 8. Лютаревич, А.Г. Применение нейронных сетей для прогнозирования параметров электропотребления / А.Г. Лютаревич // Вестник ЮГУ. – 2023. – № 2 (69). – URL: <https://cyberleninka.ru/article/n/primenenie-neyronnyh-setey-dlya-prognozirovaniya-parametrov-elektropotrebleniya> (дата обращения: 01.12.2024).
 9. Adobe, D. Adapting Internet of Things and Neural Network in Modelling Demand Side Energy Consumption and Management / D. Adobe, O. Olasunkanmi, W. Apena, S. Oyetunji. – 2021. – URL: https://www.researchgate.net/publication/350193920_Adapting_Internet_of_Things_and_Neural_Network_in_Modelling_Demand_Side_Energy_Consumption_and_Management (дата обращения: 22.04.2025).
 10. Кулбараков, М.А. К задаче прогнозирования энергопотребления с помощью нейронных сетей / М.А. Кулбараков // Молодой ученый. – 2014. – № 11 (70). – С. 22-25. – URL: <https://moluch.ru/archive/70/12122/> (дата обращения: 06.12.2025).

11. Шувалов, В.П. Оптимизация энергопотребления шлюза Интернета вещей беспроводной сети Wi-Fi / В.П. Шувалов, Е.В. Юрченко // I-methods. – 2024. – Т. 16. № 2. – URL: <http://intech-spb.com/wp-content/uploads/archive/2024/2/Shuvalov.pdf> (дата обращения: 01.02.2025).
12. Севастьянов, Б.А. Курс теории вероятностей и математической статистики : учебник для студентов вузов, обучающихся по специальностям "Математика" и "Механика" / Б.А. Севастьянов. – Изд. 3-е. – Москва : URSS, 2019. – 255 с. – (Классический учебник МГУ). – ISBN 978-5-9710-6138-0.
13. ГОСТ Р 27.102-2021 Надежность в технике. Надежность объекта. Термины и определения. – М.: Российский институт стандартизации, 2021. – 46 с.
14. Вентцель, Е.С., Овчаров, Л.А. Теория случайных процессов и ее инженерные приложения: учебное пособие для студентов высших технических учебных заведений / Е.С. Вентцель, Л.А. Овчаров. – 5-е изд., стер. – М.: КноРус, 2014. – 448 с.: ил.; 22 см. ISBN 978-5-406-03549-8.

Assessment of the Reliability of the Gateway of the Internet of Things Network Based on the Results of Forecasting its Energy Consumption

Shuvalov Vyacheslav Petrovich,
*Professor, Doctor of Technical Sciences,
Federal State Budgetary Educational Institution of Higher Education «Siberian State
University of Telecommunications and Informatics» (SibGUTI),
Novosibirsk, Russia
shvp04@mail.ru*

Budyldina Nadezhda Veniaminovna,
*associate Professor, Candidate of Technical Sciences,
Ural Technical Institute of Communications and Informatics (branch)
of the Federal State Budgetary Educational Institution
of Higher Education «Siberian State University of Telecommunications and
Informatics» in Yekaterinburg (UrTISI SibGUTI),
Yekaterinburg, Russia,
20bnv@mail.ru*

Yurchenko Evgeniya Vladimirovna,
*Senior Lecturer, Ural Technical Institute of Communications
and Informatics (branch) of the Federal State Budgetary Educational Institution
of Higher Education «Siberian State University of Telecommunications and
Informatics» in Yekaterinburg (UrTISI SibGUTI),
Yekaterinburg, Russia,
jena23@mail.ru*

The use of artificial neural networks (ANN) to solve problems in the field of power supply to Internet of Things (IOT) networks is becoming increasingly relevant. The paper considers the use of a recurrent neural network (RNN) with long-term short-term memory (LSTM, Long short-term memory) to predict the energy consumption of an Internet of Things gateway. The values of total power consumption and the volume of traffic transmitted through the gateway for various sensor polling intervals were used as input parameters for training an artificial neural network (ANN). The ANN was trained for data obtained using a linear algorithm for optimizing gateway energy consumption and Internet of Things network data obtained experimentally. A mobile phone with limited energy resources was used as the gateway to the IB network, and when it fails, the network becomes inoperable. The end devices are sensors for distance, temperature, humidity, and atmospheric pressure. The gateway's battery life has been determined (approximately 39 hours). The mathematical apparatus of Markov processes was used to assess the reliability of the gateway. Calculations have shown high short-term reliability of the gateway (99.7% in 39 hours).

Keywords: Internet of Things; optimization; energy consumption; recurrent neural network; Markov processes.