

Особенности применения импульсных нейронных сетей в задачах регрессии

E.B. Алымова

Российская таможенная академия (Ростовский филиал), Ростов-на-Дону

Аннотация: В статье представлен анализ применения импульсных нейронных сетей третьего поколения для решения задач регрессии. Рассмотрены основные модели импульсных нейронов (модель интегрирующего нейрона с утечкой, Ижикевича, Ходжкина-Хаксли) с точки зрения их вычислительной сложности и применимости к регрессионным задачам. Проанализированы методы кодирования вещественных данных в последовательности импульсов: частотное, временное и популяционное кодирование. Особое внимание уделено методам декодирования выходных импульсов в непрерывные значения, включая частотное декодирование, декодирование по времени первого импульса, использование мембранныго потенциала и популяционное голосование. Проведена оценка энергоэффективности различных подходов, продемонстрировано снижение энергопотребления в 100-200 раз по сравнению с традиционными нейронными сетями при сохранении приемлемой точности. Результаты исследования подтверждают перспективность применения импульсных сетей во встраиваемых системах и устройствах интернета вещей.

Ключевые слова: импульсные нейронные сети, модель импульсного нейрона, кодирование импульсами, регрессия, энергоэффективность.

Импульсные нейронные сети третьего поколения являются перспективным направлением в области нейроморфных вычислений [1]. В отличие от традиционных искусственных нейронных сетей второго поколения [2, 3], использующих непрерывные значения активации, импульсные сети оперируют дискретными событиями — спайками, что позволяет достичь существенного снижения энергопотребления и повышения эффективности вычислений. Актуальность исследований в области импульсных нейронных сетей обусловлена растущей потребностью в энергоэффективных решениях для встраиваемых систем, интернета вещей и мобильных устройств [4].

Современные исследования посвящены вопросам развития нейроморфных вычислений. Согласно исследованию [5] системы на основе импульсных нейронных сетей потребляют в 5.6 раз меньше энергии по сравнению с традиционными нейронными сетями при сопоставимой

точности. Специализированное нейроморфное оборудование, такое как Intel Loihi и IBM TrueNorth, обеспечивает высокую энергоэффективность благодаря асинхронной обработке событий [4, 6]. Исследование [7] предполагает возможность оптимизации энергопотребления импульсных сетей через квантование и структурную оптимизацию.

Решение задачи регрессии с помощью импульсных нейронных сетей представляет особый интерес. В отличие от задач классификации, где выходом является дискретная метка класса, регрессия требует предсказания непрерывных вещественных значений. При этом встает вопрос преобразования дискретных бинарных импульсов в непрерывные числовые значения с приемлемой точностью [8, 9]. В работе [8] предлагается решение этой проблемы через использование мембранныго потенциала нейронов для декодирования выходных значений, достигая 238-кратного снижения энергопотребления по сравнению с традиционными сетями долгой краткосрочной памяти (Long Short-Term Memory – LSTM).

Целью данной работы является систематический анализ особенностей применения импульсных нейронных сетей для решения задач регрессии, включая сравнение моделей импульсных нейронов, методов кодирования и декодирования вещественных данных, а также оценку энергоэффективности различных подходов.

Сравнительный анализ моделей импульсных нейронов

Существует несколько основных моделей импульсных нейронов, различающихся по степени биологической реалистичности и вычислительной сложности [1, 10]. Наиболее распространённые модели включают интегрирующий нейрон с утечкой (Leaky Integrate-and-Fire – LIF), модель Ижикевича, модель отклика на импульс (Spike Response Model – SRM) и более сложные модели Ходжкина-Хаксли.

Модель LIF является наиболее простой и широко используемой в задачах машинного обучения [1]. Динамика мембранныго потенциала описывается дифференциальным уравнением (1):

$$\tau_m \frac{dV}{dt} = -(V - V_{rest}) + R_m I(t) \quad (1)$$

где V — мембранный потенциал, τ_m — постоянная времени мембранны, V_{rest} — потенциал покоя, R_m — сопротивление мембранны, $I(t)$ — входной ток. Когда потенциал V достигает порогового значения V_{th} , нейрон генерирует импульс и потенциал сбрасывается до значения V_{reset} .

Модель Ижикевича представляет собой двумерную систему обыкновенных дифференциальных уравнений [8] по формулам (2):

$$\begin{aligned} \frac{dV}{dt} &= 0,04V^2 + 5V + 140 - u + I, \\ \frac{du}{dt} &= a(vB - u) \end{aligned} \quad (2)$$

где u — переменная восстановления, параметры a , b , c , d определяют различные режимы генерации импульсов. Согласно исследованию Ижикевича 2004 года, эта модель способна воспроизводить более 20 различных типов нейронной активности при вычислительной сложности, сравнимой с моделью LIF [10].

Модель LIF имеет большую практическую значимость для задач регрессии [8, 9]. Она требует минимальных вычислительных ресурсов — около 13 операций с плавающей точкой на миллисекунду модельного времени, что существенно меньше по сравнению с моделью Ижикевича (около 13 операций) и моделью Ходжкина-Хаксли (1200 операций) [10]. Модель LIF обеспечивает баланс между биологической правдоподобностью и вычислительной эффективностью. Простота модели облегчает обучение с

использованием суррогатных градиентов, что критично для обратного распространения ошибки в импульсных сетях [1].

Сравнительная характеристика моделей нейронов представлена в таблице №1.

Таблица № 1

Сравнение основных моделей импульсных нейронов

Модель	Число параметров	Вычислительная сложность (FLOPS/мс)	Биологическая реалистичность	Применимость к регрессии
LIF	4-5	~13	Средняя	Высокая
Ижикевича	4	~13	Высокая	Средняя
Ходжкина-Хаксли	10-15	~1200	Очень высокая	Низкая

Методы кодирования вещественных данных в импульсы

Преобразование вещественных входных данных в последовательности импульсов является критическим этапом для функционирования импульсных нейронных сетей [11]. Существует три основных класса методов кодирования: частотное кодирование, временное кодирование и популяционное кодирование.

При частотном кодировании (rate coding) информация о значении входного признака кодируется частотой генерации импульсов [11]. Для входного значения $x \in [0, 1]$ нормализованная частота импульсов определяется по формуле (3):

$$f = x \cdot f_{\max}, \quad (3)$$

где f_{\max} — максимальная частота импульсации.

Частотное кодирование может быть реализовано как детерминированное периодическое или стохастическое по распределению Пуассона. В последнем случае вероятность генерации импульса в каждый момент времени определяется как $P(\text{spike}) = x$, что соответствует процессу Бернулли [11].

На рис. 1 представлен результат частотного кодирования вещественного значения $x=0.7$ при частоте 70 Гц с числом импульсов 9.

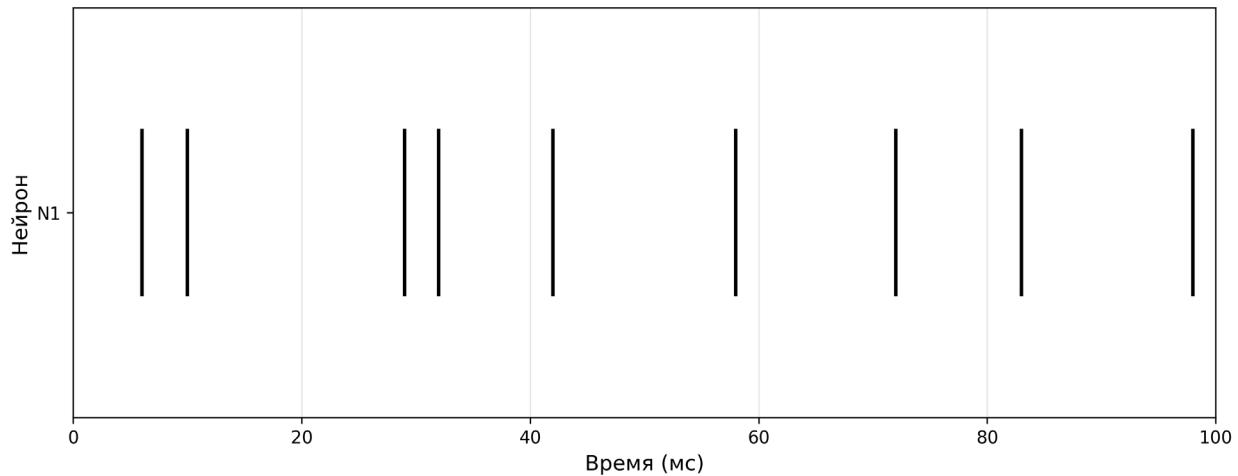


Рис. 1. – Частотное кодирование вещественного значения $x=0.7$

Временное кодирование (temporal coding) использует точное время появления импульса для передачи информации [11, 12]. Наиболее распространённым вариантом является кодирование временем до первого импульса (Time-To-First-Spike – TTFS) по формуле (4):

$$t_{\text{spike}} = t_0 + (1 - x) \cdot \Delta t, \quad (4)$$

где t_0 — начальный момент времени, Δt — временное окно кодирования. Большие значения входа приводят к более раннему появлению импульса. На рис. 2 представлен результат кодирования вещественного значения $x = 0.7$ за время импульса 15 мс.

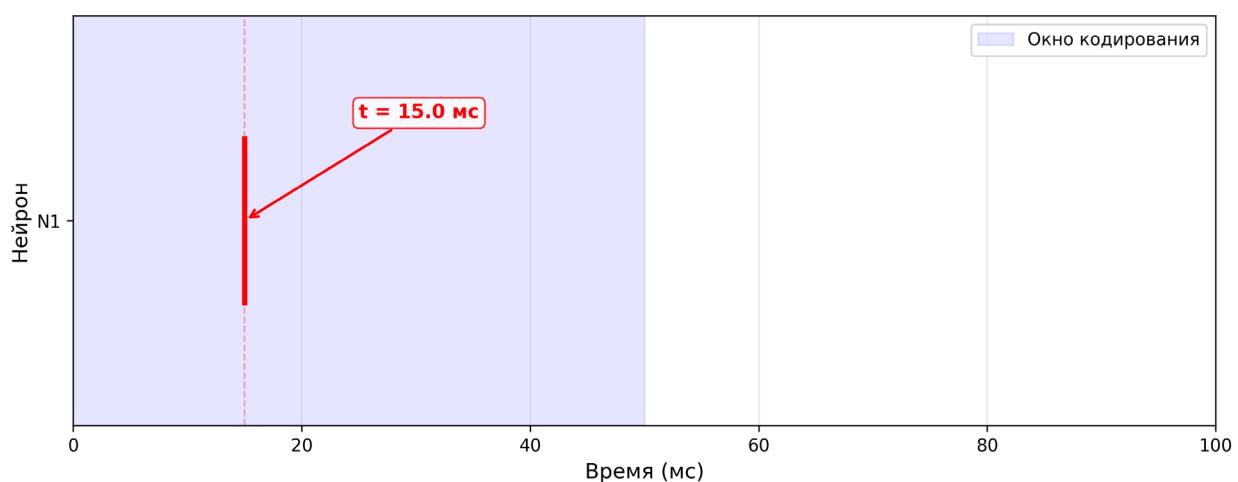


Рис. 2. – Временное кодирование вещественного значения $x=0.7$

Популяционное кодирование использует ансамбль нейронов с различными настроечными кривыми для представления одного входного значения [11]. Для входного значения x активация i -го нейрона определяется гауссовой функцией (5):

$$A_i(x) = \exp\left(-\left(\frac{(x - \mu_i)^2}{2\sigma^2}\right)\right), \quad (5)$$

где μ_i — центр настроенной кривой i -го нейрона, σ — ширина настроенной кривой.

На рис. 3 представлен результат популяционного кодирования вещественного значения $x = 0.7$, при этом максимальная активация наблюдается у нейронов 6-8.

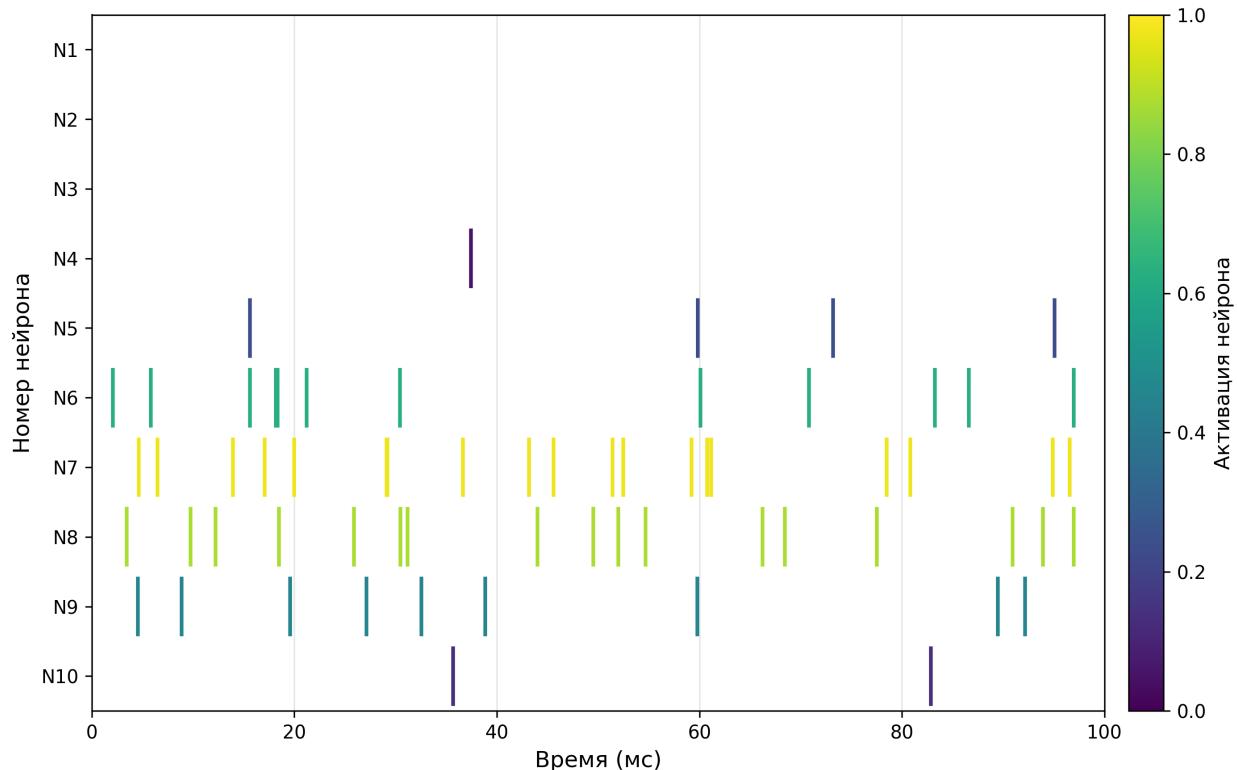


Рис. 3. – Популяционное кодирование вещественного значения $x=0.7$

С точки зрения энергоэффективности, временное кодирование имеет существенное преимущество. Оно требует значительно меньше импульсов

для передачи той же информации — обычно один импульс на нейрон, в то время как частотное кодирование может требовать десятки импульсов [4]. При этом временное кодирование с использованием относительных латентностей достигает более высокой энергоэффективности и скорости передачи данных по сравнению с частотным кодированием [12].

Однако временное кодирование более чувствительно к шуму и требует высокой временной точности [11, 12]. Для задач регрессии наиболее перспективным представляется популяционное кодирование с временной компонентой, которое сочетает робастность популяционного представления с эффективностью временного кодирования [8, 9].

Декодирование импульсов в вещественные значения

Существует несколько основных подходов к преобразованию выходных импульсов в непрерывные вещественные значения.

Частотное декодирование использует подсчёт импульсов за определённое временное окно T по формуле (6) [11]:

$$y = \frac{N_{\text{spikes}}}{T} \cdot k, \quad (6)$$

где N_{spikes} — число импульсов, k — коэффициент масштабирования.

Этот метод прост в реализации, но требует длительного временного окна для достижения приемлемой точности и высокого энергопотребления [4].

Декодирование по времени первого импульса извлекает информацию из момента появления первого импульса по формуле (7) [12]:

$$y = k_1 - k_2 \cdot t_{\text{first}}, \quad (7)$$

где t_{first} — время первого импульса, k_1 , k_2 — параметры преобразования. Этот метод обеспечивает быструю реакцию и низкое энергопотребление, но менее устойчив к шуму [12].

Декодирование на основе мембранныго потенциала использует непосредственно значение мембранныго потенциала выходного нейрона по формуле (8) [8]:

$$y = \sum w_i V_i(t_{end}), \quad (8)$$

где $V_i(t_{end})$ — мембранный потенциал i -го выходного нейрона в конечный момент времени, w_i — весовые коэффициенты. Этот подход обеспечивает высокую точность регрессии при сохранении энергоэффективности [8].

Популяционное голосование использует ансамбль выходных нейронов по формуле (9) [8, 9]:

$$y = \sum w_i f(V_i(t_{end})), \quad (9)$$

где f — нелинейная функция активации (например, softmax или sigmoid). Этот метод демонстрирует наибольшую робастность и точность в задачах нелинейной регрессии [9].

На рис. 4, рис. 5 и рис. 6 представлена схема декодирования выходных импульсов с использованием мембранных потенциалов популяции нейронов.

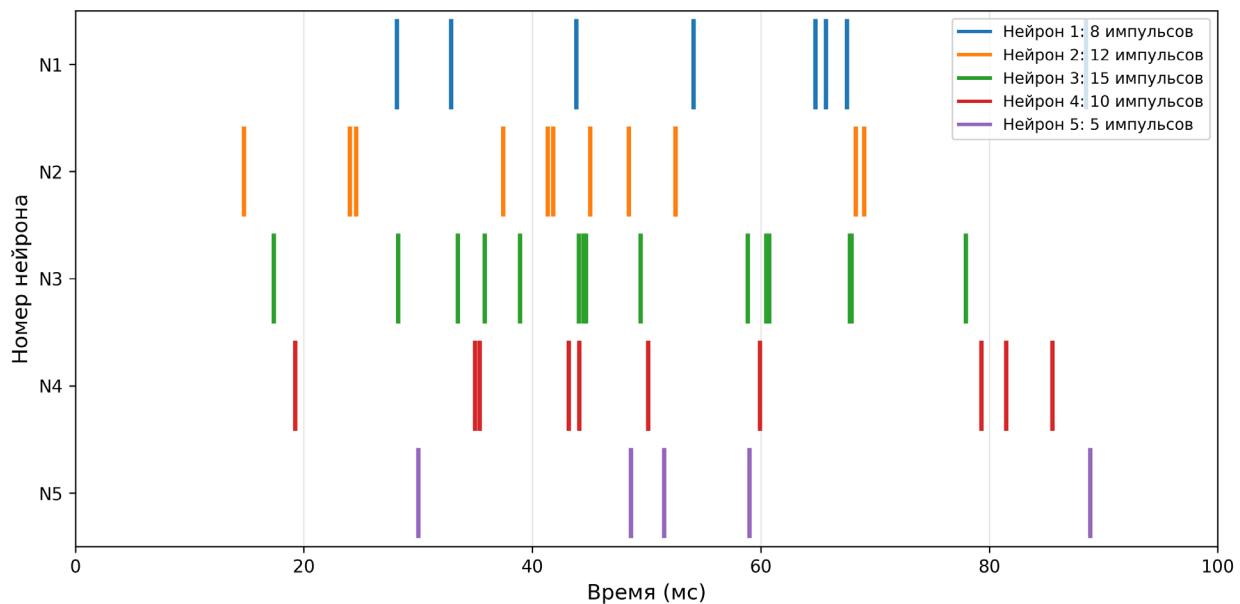


Рис. 4. – Шаблон импульсов выходных нейронов

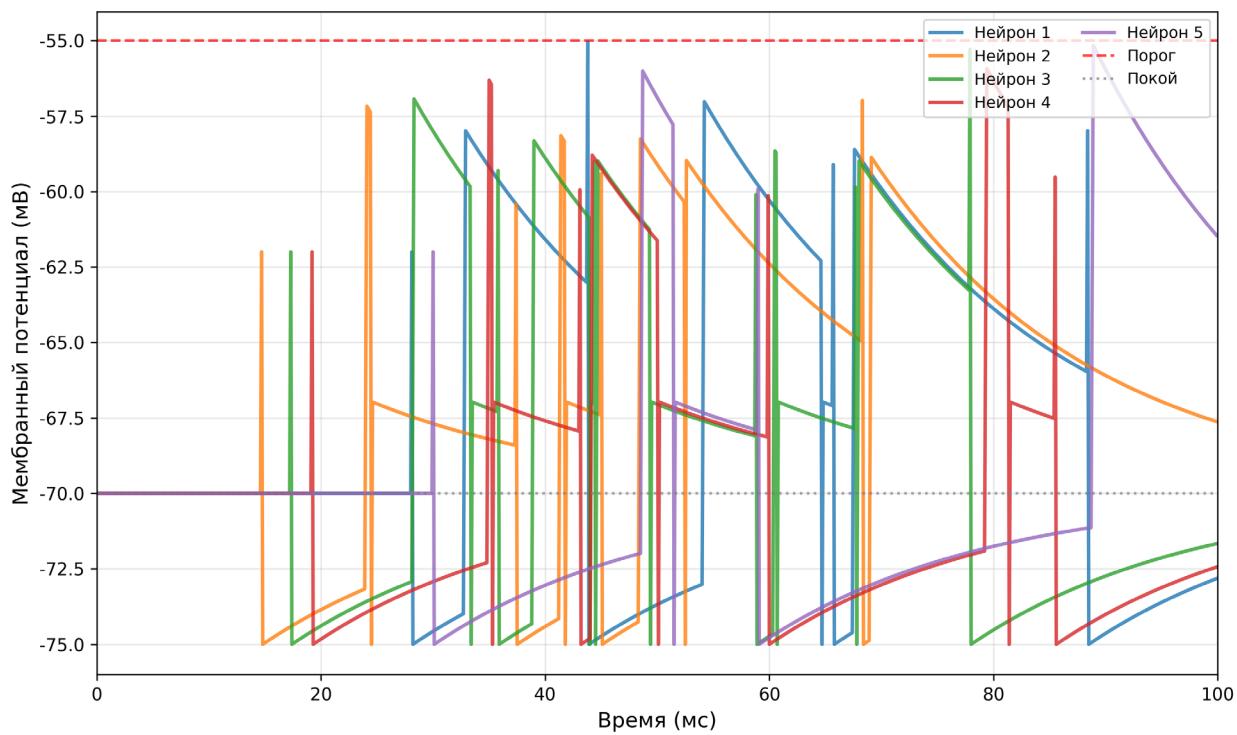


Рис. 5. – Динамика мембранных потенциалов

Для получения выходного значения осуществляется взвешенное суммирование потенциалов, как показано на рис. 6.

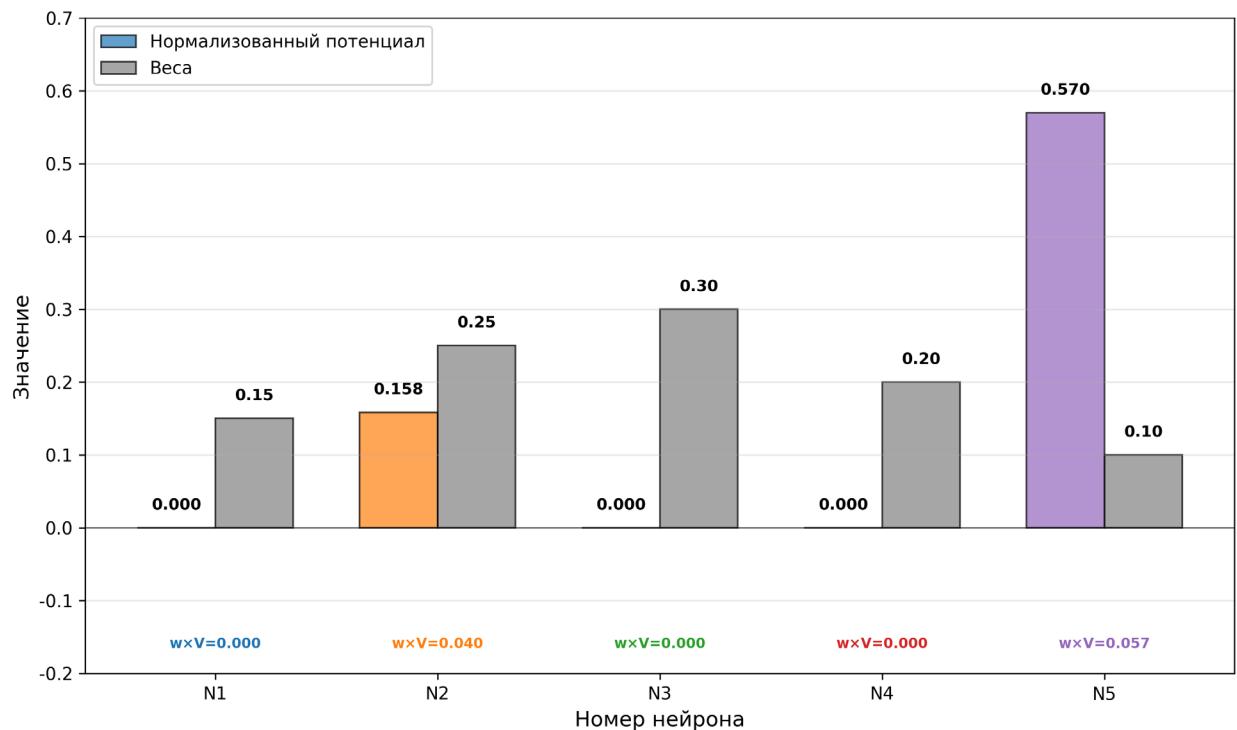


Рис. 6. – Взвешенное суммирование. Выходное значение 0.57

Сравнительный анализ методов декодирования по критериям точности, скорости и энергопотребления представлен в таблице №2.

Таблица № 2

Сравнение методов декодирования для задач регрессии

Метод декодирования	Типичная ошибка MSE	Время отклика (мс)	Среднее число импульсов	Энергоэффективность
Частотное	0.02-0.05	50-200	100-500	Низкая
Время первого импульса	0.05-0.15	5-20	1-5	Очень высокая
Мембранный потенциал	0.01-0.03	20-50	10-50	Высокая
Популяционное голосование	0.008-0.02	30-80	20-100	Высокая

Энергоэффективность импульсных сетей в задачах регрессии

Оценка энергоэффективности импульсных нейронных сетей критична для понимания их практической применимости [4, 5, 7]. Энергопотребление складывается из двух основных компонент: статического потребления в состоянии покоя и динамического потребления при обработке импульсов.

Для традиционных нейронных сетей энергопотребление пропорционально числу операций умножения-накопления (Multiply-accumulate – MAC) по формуле (10) [4]:

$$E_{\text{ANN}} = N_{\text{MAC}} \cdot E_{\text{MAC}}, \quad (10)$$

где N_{MAC} — число операций, $E_{\text{MAC}} \approx 4.6$ пДж на операцию для 45нм технологии.

Для импульсных сетей энергопотребление определяется числом импульсов по формуле (11) [4,7]:

$$E_{\text{SNN}} = N_{\text{spikes}} \cdot E_{\text{spike}} + P_{\text{leak}} \cdot T, \quad (11)$$

где N_{spikes} — общее число импульсов, $E_{\text{spike}} \approx 0.1$ пДж — энергия на импульс, P_{leak} — мощность утечки, T — время работы.

Исследование [8] демонстрирует 120-кратное снижение энергопотребления для задачи регрессии эластичности материалов и 238-кратное снижение для временных рядов. Результаты исследования [5] показывают, что энергетический коэффициент задержки (Energy-Delay Product – EDP) для импульсных сетей в 8,2 раза ниже по сравнению с традиционными нейронными сетями.

Ключевым фактором энергоэффективности является разреженность активации [5, 7]. В импульсных сетях обычно активны лишь 5-15% нейронов в каждый момент времени, в то время как в традиционных сетях активны все нейроны. Это приводит к существенному снижению числа вычислительных операций [4].

Заключение

Импульсные нейронные сети представляют собой перспективную технологию для решения задач регрессии с высокой энергоэффективностью [8, 9]. Модель LIF-нейрона обеспечивает оптимальный баланс между вычислительной простотой и функциональными возможностями, что делает её наиболее подходящей для практических приложений регрессии [1, 10].

Для эффективного решения задач регрессии имеет смысл использовать популяционное кодирование входных данных с временной компонентой, что обеспечивает устойчивость к шуму при сохранении энергоэффективности [11, 12]. Для декодирования выходных значений наиболее перспективным является подход, основанный на мембранных потенциалах с популяционным голосованием, позволяющий достичь высокой точности при умеренном числе импульсов [8, 9].

Энергетические преимущества импульсных сетей наиболее выражены при разреженной активации нейронов (менее 15% активных нейронов), что естественным образом достигается при использовании временного кодирования [4, 5, 7]. Снижение энергопотребления в 100-200 раз по

сравнению с традиционными нейронными сетями открывает возможности для применения импульсных сетей во встраиваемых системах, носимых устройствах и сенсорных сетях интернета вещей.

Литература

1. Eshraghian J.K., Ward M., Neftci E. et al. Training Spiking Neural Networks Using Lessons From Deep Learning // Proceedings of the IEEE. 2023. Vol. 111, No. 9. pp. 1016-1054.
 2. Зенков В.А., Панищев В.С., Желанов А.Л., Волков Д.А. Сверточная нейронная сеть для сопоставления изображений товаров // Инженерный вестник Дона, 2024, №8. URL: ivdon.ru/ru/magazine/archive/n8y2024/9444.
 3. Алымова Е.В. Совместное применение модели линейной регрессии и нейронной сети в задаче предсказания тренда котировок криптовалюты Bitcoin // Инженерный вестник Дона, 2020, №10. URL: ivdon.ru/ru/magazine/archive/n10y2020/6637.
 4. Rathi N., Chakraborty I., Kosta A. et al. Exploring Neuromorphic Computing Based on Spiking Neural Networks: Algorithms to Hardware // ACM Computing Surveys. 2023. Vol. 55, No. 12. pp. 1-49.
 5. Ding, J., Yu, Z., Liu, J.K. et al. Neuromorphic computing paradigms enhance robustness through spiking neural networks // Nature Communications. 2025. Vol. 16. Article 10175.
 6. Davies M., Srinivasa N., Lin T.-H. et al. Loihi: A Neuromorphic Manycore Processor with On-Chip Learning // IEEE Micro. 2018. Vol. 38, No. 1. pp. 82-99. URL: researchgate.net/publication/322548911_Loihi_A_Neuromorphic_Manycore_Processor_with_On-Chip_Learning.
 7. Sorbaro M., Liu Q., Bortone M., Sheik S. Optimizing the Energy Consumption of Spiking Neural Networks for Neuromorphic Applications // Frontiers in Neuroscience. 2020. Vol. 14. Article 662. URL:
-

researchgate.net/publication/342574604_Optimizing_the_Energy_Consumption_of_Spiking_Neural_Networks_for_Neuromorphic_Applications.

8. Henkes A., Eshraghian J.K., Wessels H. Spiking neural networks for nonlinear regression // Royal Society Open Science. 2024. Vol. 11. Article 231606. URL: researchgate.net/publication/380246687_Spiking_neural_networks_for_nonlinear_regression.

9. Tandale A., Stoffel M. Spiking neural networks for nonlinear regression of complex transient signals on sustainable neuromorphic processors // npj Unconventional Computing. 2025. Vol. 1. Article 2. URL: researchgate.net/publication/380246687_Spiking_neural_networks_for_nonlinear_regression.

10. Izhikevich E.M. Which Model to Use for Cortical Spiking Neurons? // IEEE Transactions on Neural Networks. 2004. Vol. 15, No. 5. pp. 1063-1070.

11. Schuman C.D., Kulkarni S.R., Parsa M. et al. A Survey of Encoding Techniques for Signal Processing in Spiking Neural Networks // Neural Processing Letters. 2022. Vol. 53. pp. 4693-4710.

12. Wu G., Liang D., Luan S., Wang J. Training Spiking Neural Networks for Reinforcement Learning Tasks With Temporal Coding Method // Frontiers in Neuroscience. 2022. Vol. 16. Article 877701. URL: researchgate.net/publication/362768964_Training_Spiking_Neural_Networks_for_Reinforcement_Learning_Tasks_With_Temporal_Coding_Method.

References

1. Eshraghian J.K., Ward M., Neftci E. et al. Proceedings of the IEEE. 2023. Vol. 111, No. 9. pp. 1016-1054.
 2. Zenkov V.A., Panishchev V.S., Zhelanov A.L., Volkov D.A. Inzhenernyj vestnik Dona, 2024, №8. URL: ivdon.ru/ru/magazine/archive/n8y2024/9444.
 3. Alyanova E. V. Inzhenernyj vestnik Dona, 2020, №10. URL: ivdon.ru/ru/magazine/archive/n10y2020/6637.
-

4. Rathi N., Chakraborty I., Kosta A. et al. ACM Computing Surveys. 2023. Vol. 55, No. 12. pp. 1-49.
5. Ding, J., Yu, Z., Liu, J.K. et al. Nature Communications. 2025. Vol. 16. Article 10175.
6. Davies M., Srinivasa N., Lin T.-H. et al. IEEE Micro. 2018. Vol. 38, No. 1. pp. 82-99. URL: researchgate.net/publication/322548911_Loihi_A_Neuromorphic_Manycore_Processor_with_On-Chip_Learning.
7. Sorbaro M., Liu Q., Bortone M., Sheik S. Frontiers in Neuroscience. 2020. Vol. 14. Article 662. URL: researchgate.net/publication/342574604_Optimizing_the_Energy_Consumption_of_Spiking_Neural_Networks_for_Neuromorphic_Applications.
8. Henkes A., Eshraghian J.K., Wessels H. Royal Society Open Science. 2024. Vol. 11. Article 231606. URL: researchgate.net/publication/380246687_Spiking_neural_networks_for_nonlinear_regression.
9. Tandale A., Stoffel M. npj Unconventional Computing. 2025. Vol. 1. Article 2. URL: researchgate.net/publication/380246687_Spiking_neural_networks_for_nonlinear_regression.
10. Izhikevich E.M. IEEE Transactions on Neural Networks. 2004. Vol. 15, No. 5. pp. 1063-1070.
11. Schuman C.D., Kulkarni S.R., Parsa M. et al. Neural Processing Letters. 2022. Vol. 53. pp. 4693-4710.
12. Wu G., Liang D., Luan S., Wang J. Frontiers in Neuroscience. 2022. Vol. 16. Article 877701. URL: researchgate.net/publication/362768964_Training_Spiking_Neural_Networks_for_Reinforcement_Learning_Tasks_With_Temporal_Coding_Method.

Авторы согласны на обработку и хранение персональных данных.

Дата поступления: 24.10.2025

Дата публикации: 10.12.2025
