

Моделирование гедонистического синапса в LIF-нейроне и его применение в спайковых нейронных сетях

Азарян Сергей,
Отарян Кнар

DOI: <https://doi.org/10.58726/27382923-2026.1ns-69>

Ключевые слова: пластичность, модулируемая вознаграждением, гедонистическое обучение, суррогатный градиент, обучение с подкреплением, временная обработка сигналов, численное моделирование

Введение

Данная работа посвящена концепции гедонистического синапса - особого типа нейронной связи, сила которого динамически изменяется под воздействием **глобального сигнала вознаграждения**. Цель исследования заключается в изучении и формализации механизма *reward-modulated learning* в рамках динамики нейрона типа *Leaky Integrate-and-Fire (LIF)* и демонстрации его применимости в гибридных SNN+RL системах и задачах классификации **многомерных временных сигналов**.

Для достижения поставленной цели решены следующие задачи:

1. Смоделировать LIF нейрон и гедонистический синапс в среде Python 3.12.2, обеспечивая корректное численное интегрирование мембранного потенциала и синаптических весов.
2. Реализовать правило *reward-punishment* и исследовать его влияние на динамику синаптических связей.
3. Провести теоретический анализ устойчивости модели, определить условия ограниченности синаптических весов и проверить стабильность численной схемы.
4. Выполнить численное моделирование и визуализацию результатов, включая динамику мембранного потенциала и *spike raster plot*.

Новизна работы заключается в интеграции глобально-модулируемого сигнала вознаграждения с динамикой LIF нейрона и применении surrogate gradient методов для обучения на основе спайков, что открывает возможности для построения биологически правдоподобных гибридных SNN + RL архитектур.

Актуальность исследования обусловлена необходимостью динамически адаптивных связей в современных задачах обработки временных рядов и *reinforcement learning*, где классические локальные правила пластичности не обеспечивают достаточную эффективность.

Теоретическая значимость работы состоит в разработке формализованной модели гедонистического синапса, включающей мембранный потенциал, синаптические веса, функцию eligibility trace и дофаминоподобный сигнал вознаграждения, с проведением анализа устойчивости.

Практическая значимость заключается в возможности применения модели для построения эффективных и стабильных гибридных систем SNN + RL, а также для задач классификации многомерных временных сигналов, что может способствовать дальнейшему развитию методов biologically plausible learning и спайковых нейронных сетей.

1. Численные методы моделирования динамических систем

Моделирование спайковых нейронных сетей основано на решении систем дифференциальных уравнений, описывающих динамику мембранного потенциала нейрона. В рамках численной реализации используются методы дискретизации, в частности явные схемы интегрирования типа метода Эйлера, позволяющие аппроксимировать непрерывную динамику во временной сетке. Теоретические основы численных методов решения дифференциальных уравнений и анализа устойчивости изложены в работе [1; 3].

Численная устойчивость и шаг интегрирования являются критически важными параметрами при моделировании спайковых процессов, поскольку нелинейная пороговая динамика чувствительна к величине дискретизации.

Спайковые нейронные сети (SNN) [2-3; 7] представляют третье поколение искусственных нейронных сетей и моделируют обработку информации посредством дискретных событий - спайков. В отличие от классических многослойных сетей с непрерывными активациями [3], SNN учитывают временную структуру сигналов, что делает их особенно эффективными для обработки временных и событийных данных. Базовой моделью нейрона в работе используется модель интегрирования и порога (LIF — Leaky Integrate-and-Fire), описываемая дифференциальным уравнением:

$$T_m \frac{dV(t)}{dt} = -V(t) + RI(t) \quad (1)$$

Где

$V(t)$ — мембранный потенциал, $I(t)$ — входной ток, T_m — постоянная времени мембраны,

R — сопротивление

Мембранный потенциал нейрона, $V(t)$, изменяется в соответствии с дифференциальным уравнением:

$$T \frac{dV(t)}{dt} = -(V - V_{rest}) + wI_{ext} + \sigma\xi(t) \quad (2)$$

Где

V_{rest} — потенциал покоя, T — постоянная времени, w — синаптический вес,

I_{ext} — внешний поток, $\sigma\xi(t)$ — гауссовский шум,

В коде используется дискретизация Эйлера.

$$V_{t+dt} = V_t + dV \quad (3)$$

Где

$$dV = \left(\frac{-(V - V_{rest}) + wI_{ext}}{T} + \sigma N(0,1) \right) dt \quad (4)$$

При достижении порогового значения $V_i(t) \geq V_{th}$ генерируется спайк, после чего потенциал сбрасывается до значения покоя. Таким образом, динамика LIF-нейрона позволяет формализовать временную интеграцию входных сигналов и реализовать событийно-ориентированное вычисление.

SNN широко применяются в задачах распознавания образов, сенсорной обработки и обработки событийных потоков что подтверждает их вычислительный потенциал в задачах временной динамики. SNN широко применяются в задачах распознавания

образов и сенсорной обработки, что подтверждает их вычислительный потенциал в задачах обработки событийных потоков.

Гедонистические синапсы особенно тесно связаны с системой вознаграждения мозга. Дофамин играет ключевую роль в формировании ощущения удовольствия и мотивации. Центральное значение имеют области среднего мозга, включая вентральную область покрышки (VTA) и прилежащее ядро, которые участвуют в механизмах вознаграждения.

Гедонистические синапсы часто активируются приятными стимулами, такими как еда, музыка, физическая активность или социальное взаимодействие. Такой синапс представляет собой нейронное соединение, сила которого (вес) изменяется в зависимости от сигналов о награде или наказании. Это означает, что если действие привело к положительному результату (награде), эта связь усиливается. Если действие привело к отрицательному результату (наказанию), эта связь ослабевает.

Таблица 1

Сравнение с нормальным синапсом

Тип синапса	Изменение силы	Реакция
Обычный (Hebbian)	Зависит от соответствия активности до и после (fire together, wire together)	Обучение на основе точной синхронной активации
Гедонистический	Зависит от переменных внешних сигналов (reward/punishment)	Более «программируемое» или каноническое обучение, соответствующее цели.




Рисунок 1. Структура нейрона и его электрическая модель

В рамках данного исследования мы моделировали концепцию гедонистического синапса с использованием языка Python, реализуя простую нейронную сеть или алгоритм, функционирующий по принципу вознаграждения и наказания. Такой подход позволяет изучать механизмы адаптивной синаптической пластичности в контролируемой вычислительной среде и обеспечивает наглядное представление процессов обучения нейронов.

2. Глобальная модуляция пластичности и гедонистический принцип

В биологических нейронных системах изменение силы синаптических связей определяется не только локальными корреляциями активности, например, механизмом STDP, но и глобальными нейромодуляторными сигналами. Гедонистическая пластичность функционально связана с системой вознаграждения мозга, включающей дофаминергические пути и структуры среднего мозга, участвующие в формировании мотивационного подкрепления.

С вычислительной точки зрения, гедонистический синапс представляет собой синаптическую связь, изменение веса которой регулируется глобальным сигналом подкрепления $r(t)$. Простейшее правило адаптации можно записать следующим образом:

$$\Delta w = \eta r(t) S_{pre} \quad (2)$$

где η – коэффициент обучения, $r(t)$ – сигнал вознаграждения (положительный или отрицательный), S_{pre} – активность пресинаптического нейрона [7].

Если результат действия приводит к положительному подкреплению ($r > 0$), связь усиливается; при отрицательном ($r < 0$) – ослабляется. Таким образом, обучение носит глобально-модулируемый характер и не требует вычисления градиента ошибки, что делает модель биологически интерпретируемой и вычислительно простой.

2.1. Импульсные нейронные сети

Отсутствие возможности выразить временную динамику биологических нейронов в смоделированных до сих пор искусственных нейронных сетях привело к появлению новых методов построения искусственных нейронных сетей, основанных на более биологически надежных нейронных моделях: импульсных нейронных сетях.

Нейроморфные вычисления предполагают выполнение вычислений биологически правдоподобным образом. Одним из важнейших типов нейроморфных вычислений являются нейронные сети. Спайковая нейронная сеть [5] – один из ведущих подходов к преодолению ограничений нейронных вычислений и эффективному использованию алгоритмов машинного обучения в реальных приложениях. Концепция сверточных нейронных сетей, часто считающихся нейронными сетями третьего поколения, реализуется с использованием биологических нейронных механизмов: Mami, который может эффективно обрабатывать дискретные пространственно-временные сигналы (**spikes**).

Интеграторно-активирующий нейрон с уткой (LIF-нейрон) – это простая модель активирующего нейрона, который можно охарактеризовать внутренним состоянием, называемым мембранным потенциалом. Мембранный потенциал интегрирует входные сигналы с течением времени и генерирует выходной импульс, когда этот потенциал пересекает порог активации нейрона. В последнее время такие нейроны были разработаны для использования в специализированном оборудовании, основанном на асинхронной архитектуре сигналов.

Что означает, что нейрон «сработал» (произошел импульс)?

В нейронных сетях, особенно в импульсных нейронных сетях (SNN-Spiking Neural Networks), нейрон «срабатывает», когда его мембранный потенциал (membrane potential) превышает определенный порог (threshold).

- **Spiking** означает, что нейрон посылает электрический импульс, который воздействует на соединённые с ним нейроны. С биологической точки зрения это то же самое, что «активация» нервной клетки при передаче информации через синапс к следующему нейрону.

- **Hedonic Synapse Learning** – Гедонистический синапс устроен таким образом, что сила (weight) синапса регулируется в зависимости от «привлекательности» – то есть, если дан правильный ответ, он усиливает соответствующие связи.




Рисунок 2. Схема работы и обучения нейрона типа Leaky Integrate-and-Fire neuron в спайковых нейронных сетях

На рис. 2 представлена полная вычислительная и обучающая схема нейрона типа Leaky Integrate-and-Fire (LIF). Мембранный потенциал нейрона не только интегрирует входные сигналы во времени, но и подвержен процессу естественного затухания (утечки), что обеспечивает динамическое моделирование биологически правдоподобного поведения. При превышении порогового значения формируется выходной импульс (спайк), после чего мембранный потенциал сбрасывается.

Поскольку функция генерации спайка является дискретной и недифференцируемой, в процессе обучения применяются методы surrogate gradient, позволяющие аппроксимировать производную пороговой функции гладкой заменой и тем самым обеспечить возможность градиентной оптимизации.

Изменение синаптических весов (Δw) осуществляется на основе градиентного подхода и может зависеть от сигнала ошибки или вознаграждения, что реализует меха-

низм гедонистического обучения. Вся система функционирует в рамках замкнутого контура обратной связи, где выходная активность нейрона влияет на последующую корректировку синаптических параметров, обеспечивая адаптивное обучение сети.

3. Кодирование информации

В спайковых нейронных сетях информация передаётся дискретными импульсами. Основными механизмами кодирования считаются частотное кодирование (rate coding) и временное кодирование (temporal coding). В первом случае информация определяется средней частотой спайков, во втором – точным временем их возникновения.

Несмотря на широкое использование частотного подхода, нейробиологические исследования показывают, что исключительно частотный механизм не полностью объясняет высокоскоростную обработку информации в мозге. Поэтому в моделях SNN учитывается как частота, так и временная структура спайков.

Локальные механизмы обучения, такие как STDP (Spike-Timing-Dependent Plasticity), корректируют вес синапса в зависимости от относительного времени пресинаптических и постсинаптических спайков.

Если пресинаптический спайк предшествует постсинаптическому, вес увеличивается; в противоположном случае – уменьшается. Такое правило является локальным по пространству и времени и эффективно для обработки пространственно-временных паттернов.

3.1 Метод обратного распространения и модель LIF

Для достижения более высокой точности классификации в SNN используются градиентные методы обучения. Однако функция активации спайкового нейрона недифференцируема, что затрудняет применение стандартного обратного распространения ошибки.

В работе используется модель Leaky Integrate-and-Fire (LIF), описываемая уравнением:

$$T_m \frac{dV_{mem}}{dt} = -V_{mem} + I(t); \quad (3)$$

где

$$I(t) = \sum_{i=1}^{n^l} \left\{ w_i * \sum_k [\theta_i(t - t_k)] \right\}; \quad (4)$$

$$\theta_i(t - t_k) = \begin{cases} 1, & \text{если } t = t_k; \\ 0, & \text{иначе} \end{cases}; \quad (5)$$

Это взвешенная сумма входных импульсов, n^l – количество нейронов, t_k – время импульса.

При достижении порога нейрон генерирует спайк и его потенциал сбрасывается. Дискретизация уравнения выполняется методом Эйлера.

3.2 Кодирование входных данных и прямой проход

Поскольку входные изображения являются статическими, их пиксельные значения преобразуются в пуассоновские спайковые поезда. Пусть $x_i \in [0,1]$ нормированное значение i -го пикселя. Тогда входной процесс моделируется как

$$S_i(t) \sim \text{Poisson}(\lambda_i), \quad \lambda_i = \alpha x_i \quad (6)$$

В прямом проходе входные спайки умножаются на соответствующие синаптические веса, формируя входной ток, интегрируемый в мембранном потенциале постсинаптического нейрона согласно уравнению (3).

3.3. Приближение производной функции активации и переход к гедонистическому обучению

В спайковых нейронных сетях функция активации LIF-нейрона является ступенчатой и недифференцируемой, что делает невозможным прямое применение стандартных методов градиентного спуска. Для решения данной проблемы вводится аппроксимация производной с использованием непрерывной функции.

С учётом эффекта утечки мембранного потенциала вклад каждого входного спайка со временем экспоненциально затухает:

$$f(t) = \sum_k \exp\left(-\frac{t - t_k}{T_m}\right) \quad (7)$$

где:

t_k — момент k -го входного спайка,

T_m — постоянная времени мембраны.

Функция $f(t)$ моделирует фильтрацию низких частот, отражая постепенное угасание влияния предыдущих спайков на мембранный потенциал.

На её основе приближённая производная функции активации LIF-нейрона определяется как:

$$\frac{\partial \alpha_{LIF}}{\partial net} = \frac{1}{V_{th}} f(t) \quad (8)$$

где:

V_{th} — порог активации нейрона,

net — суммарный входной сигнал нейрона.

Такой подход позволяет учитывать динамическую фильтрацию и масштабирование производной при обучении с помощью метода обратного распространения.

3.3.1 Двухэтапное вычисление производной в скрытых слоях

В скрытых слоях вычисление производной происходит в **два этапа**:

1. Линейная аппроксимация без учёта утечки.
2. Экспоненциальная фильтрация с помощью функции $f(t)$, которая одновременно:
 - сглаживает временные флуктуации,
 - масштабирует производную,
 - выполняет роль фильтра низких частот.

В последнем слое влияние утечки рассматривается как шум, а суммарный потенциал оценивается как взвешенная сумма входных спайков.

Примечание: Такая аппроксимация сохраняет вычислительную устойчивость градиентного метода и предотвращает взрыв или затухание градиентов.

Однако данный метод является **эвристическим**. Он широко используется в

литературе [3,7], но не имеет строгого биологического обоснования и не учитывает глобальные сигналы вознаграждения.

3.3.2. Переход к гедонистическому обучению

В качестве альтернативы можно использовать **гедонистический принцип (hedonic learning rule)**.

Идея: изменение силы синапсов модулируется не только локальными корреляциями, но и **глобальным сигналом вознаграждения или наказания**.

В этом случае производная функции активации заменяется величиной, пропорциональной **гедонистическому сигналу**.

Такой подход позволяет интегрировать динамику LIF-нейрона с механизмом глобальной оценки полезности действий сети.

Глобальный сигнал вознаграждения можно интерпретировать как аналог **дофаминергического сигнала** в биологических системах. В задачах обучения с подкреплением он соответствует функции вознаграждения.

Таким образом предложенный подход объединяет:

- аппроксимацию производной LIF-нейрона,
- механизм глобальной модуляции обучения.

Это расширяет возможности применения SNN в задачах, где важно учитывать:

- **временную динамику,**
- **сигналы подкрепления.**

Иллюстрация временной динамики мембранного потенциала и различий между градиентным и гедонистическим обучением представлена на рис. 3.

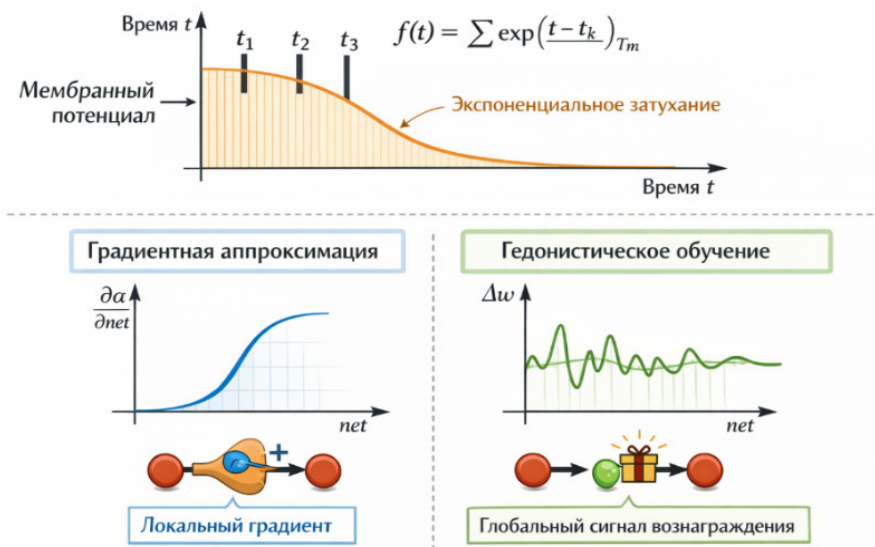


Рисунок 3. Временная динамика мембранного потенциала LIF-нейрона и приближение производной функции активации в рамках градиентного и гедонистического обучения.

4. Численная реализация и экспериментальные результаты

4.1. Параметры модели

Численное моделирование выполнено для LIF-нейрона с гедонистически модулируемой синаптической пластичностью. Использовались следующие параметры:

- постоянная времени мембраны $\tau=20$ ms,
- шаг дискретизации $dt=0.1$ ms,
- порог активации $V_{th}=1.0$,
- скорость обучения $\eta=0.01$,
- максимальный вес $w_{max}=3.0$

Мембранный потенциал эволюционирует согласно дискретизированному уравнению LIF (схема Эйлера):

$$V_{t+1} = V_t + \frac{dt}{T}(-V_t + I_t), \quad (9)$$

где входной ток определяется взвешенной суммой спайковых сигналов.

4.2. Алгоритм гедонистического обновления весов

Изменение синаптического веса осуществляется под действием глобального сигнала вознаграждения:

$$w_{t+1} = w_t + \eta R_t,$$

Где $R_t = N_{target} - N_{actual}$ -

разность между целевым и фактическим числом спайков. Для обеспечения устойчивости используется ограничение весов:

$$w \in [0, w_{max}].$$

Ниже приведён фрагмент программной реализации.

```
File Edit Format Run Options Window Help
import numpy as np
for t in range(T):
    v += dt/tau * (-v + I[t])
    if v >= v_th:
        spike = 1
        v = 0.0
    else:
        spike = 0
    spike_count += spike
reward = target_spikes - spike_count
w += eta * reward
w = np.clip(w, 0.0, w_max)
```

Представленный код отражает ключевой механизм адаптации, тогда как вспомогательные процедуры (инициализация, визуализация, экспорт данных) опущены для компактности изложения.

4.3. Экспорт и визуализация результатов

Моделирование выполнено на языке Python 3.12 с использованием библиотек NumPy и Matplotlib.

В ходе эксперимента автоматически формировались графики:

- динамики мембранного потенциала;

- спайковой активности (spike-raster);
- эволюции синаптического веса.

Результаты сохранялись в формате PDF, что обеспечивает воспроизводимость вычислительного эксперимента.

4.4. Анализ полученных результатов

Численный эксперимент показал (см. рис. 4–5):

- устойчивость динамики мембранного потенциала при малом шаге дискретизации;
- ограниченность весов при использовании процедуры отсечения;
- эффективную адаптацию синаптических коэффициентов к целевой активности;
- отсутствие дивергенции при корректном выборе скорости обучения.

Таким образом, гедонистический механизм демонстрирует стабильное поведение даже в многонейронной конфигурации. Полученные результаты (см. рис. 4, 5) подтверждают возможность интеграции глобального сигнала вознаграждения в динамические модели спайковых нейронов без потери численной устойчивости.

Trial 2: Multi-neuron SNN + RL + Raster

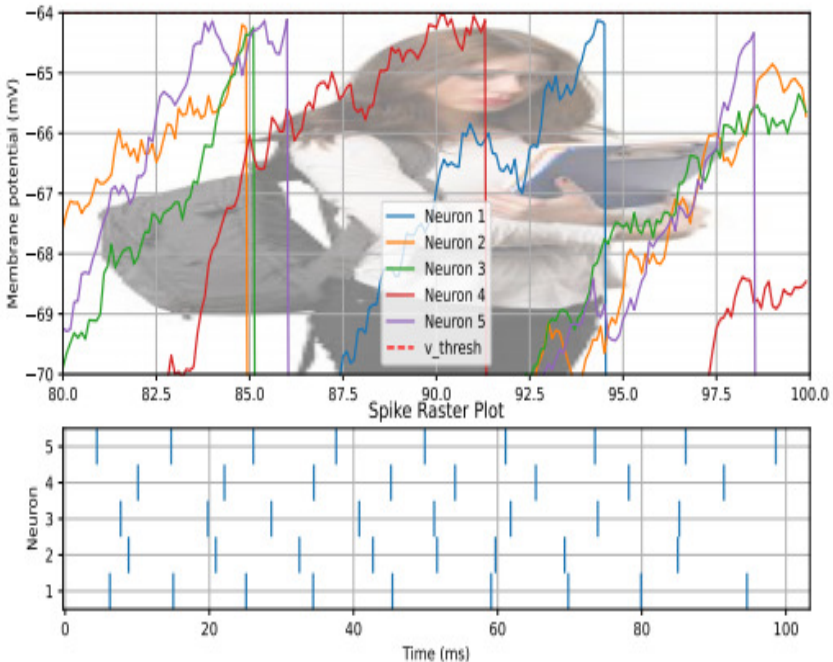


Рисунок 4. Мембранные потенциалы и spike-raster SNN (испытание 2)

Trial 5: Multi-neuron SNN + RL + Raster

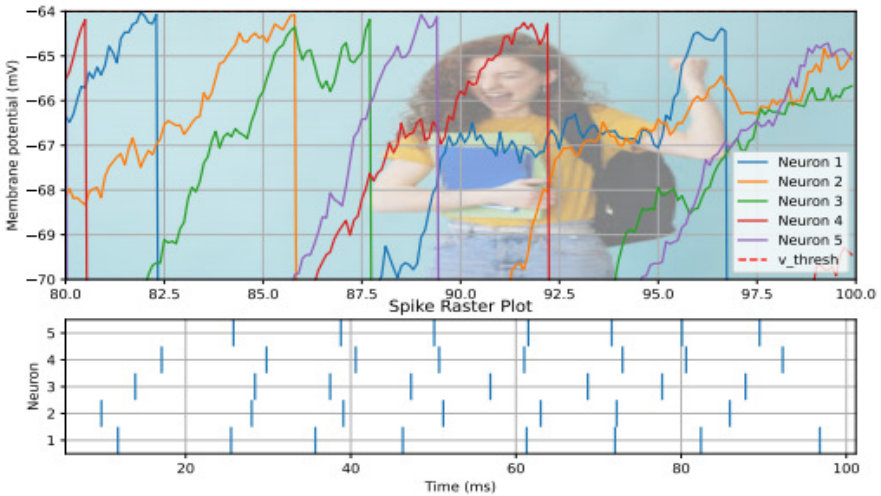


Рисунок 5. Мембранные потенциалы и spike-raster SNN (испытание 5)

Заключение

Показано, что гедонистические синапсы обеспечивают эффективный механизм глобально-модулируемой пластичности в спайковых нейронных сетях. Предложенная модель объединяет динамику LIF-нейрона и сигнал вознаграждения, что позволяет реализовать биологически правдоподобное обучение.

Численные эксперименты подтверждают устойчивость системы и способность весов адаптироваться под действием глобального сигнала. Модель может служить основой для построения гибридных SNN-RL архитектур и дальнейших исследований глобальной пластичности.

DOI: <https://doi.org/10.58726/27382923-2026.1ns-69>

Литература

1. Նավոյան Վ. Խ., Օթարյան Բ. Վ. Բարձրագույն մաթեմատիկայի լաբորատոր աշխատանքներ (թվային մեթոդներ). Երևան, ԵՊՀ հրատ., 2011, 68 էջ:
2. Евграфов В. А., Ильюшин Е. А. Спайковые нейронные сети // International Journal of Open Information Technologies, 2021. № 7.
3. Gerstner W., Kistler W. Spiking Neuron Models: Single Neurons, Populations, Plasticity, Cambridge: Cambridge University Press, 2002, 496 p.
4. Kloeden P. E., Platen E. Numerical Solution of Stochastic Differential Equations. Berlin, Heidelberg: Springer, 1992, 632 p.
5. Krizhevsky A., Sutskever I., Hinton G. E. ImageNet classification with deep convolutional neural networks // Advances in Neural Information Processing Systems, 2012, Vol. 25, p. 1097-1105.

6. Ke L., Hu M. Spatio Temporal Cluster Triggered Encoding for Spiking Neural Networks, 2025.
7. Paugam-Moisy H., Bohte S. Computing with Spiking Neuron Networks. Handbook of Natural Computing. Berlin, Heidelberg: Springer, 2012, p. 335-376.
8. Ratnasingam S., McGinnity T. A spiking neural network for tactile form-based object recognition // Proceedings of the International Joint Conference on Neural Networks (IJCNN), 2011, p. 880-885.
9. Frémaux N., Sprekeler H., Gerstner W. Functional requirements for reward-modulated spike-timing-dependent plasticity. Journal of Neuroscience, 2010, Vol. 30, No. 40, p. 13326-13337.

**Հեղոնիկ սինապսի մոդելավորում LIF նեյրոնում և
դրա կիրառությունը սփայքային նեյրոնային ցանցերում**

*Ազարյան Սերգեյ,
Օթարյան Քնար*

Ամփոփում

***Հանգուցային բառեր.** (LIF), պարզևով մոդուլացվող պլաստիկություն (Reward-Modulated Plasticity), հեղոնիկ ուսուցում, փոխարինող գրադիենտ, ամրապնդմամբ ուսուցում, ժամանակային ազդանշանների մշակում, թվային մոդելավորում*

Ներկայացված աշխատանքում ուսումնասիրվում են հեղոնիկ սինապսի մոդելը և դրա կիրառությունը սպայքային նեյրոնային ցանցերում (SNN): Քննարկվում է Leaky Integrate-and-Fire (LIF) նեյրոնի մոդելը, որտեղ սինապսային կշիռների փոփոխությունը պայմանավորված է գլոբալ պարզևատրման ազդանշանով: Առաջարկված մոտեցումը լրացնում է տեղային պլաստիկության մեխանիզմները (օրինակ՝ STDP) և հնարավորություն է տալիս իրականացնել գլոբալ մոդուլացվող ուսուցում: Մոդելավորումը իրականացվել է Python 3.12 միջավայրում՝ կիրառելով էյլերի թվային մեթոդը: Ուսուցումը հիմնված է պարզև/պատիժ մեխանիզմի վրա՝ կախված նպատակային արժեքից սպայքերի թվի շեղումից: Ստացված արդյունքները ցույց են տալիս համակարգի թվային կայունությունը, կշիռների սահմանափակվածությունը և սինապսային գործակիցների արդյունավետ ադապտացիան: Ցույց է տրվել, որ հեղոնիկ ուսուցումը կարող է արդյունավետ կիրառվել ժամանակային ազդանշանների մշակման խնդիրներում և հանդիսանալ կենսաբանական առումով հավաստի ուսուցման հիմք: Առաջարկված մոդելը կարող է օգտագործվել որպես փորձարարական հարթակ՝ գլոբալ պլաստիկության ուսումնասիրության և SNN-RL հիբրիդային համակարգերի զարգացման համար:

Modeling of a Hedonic Synapse in a LIF Neuron and its Application to Spiking Neural Networks

*Azaryan Sergey,
Otaryan Knar*

Summary

Key words: *(LIF), Reward-Modulated Plasticity, Hedonic Learning, Surrogate Gradient, Reinforcement Learning, Temporal Signal Processing, Numerical Simulation*

This work investigates hedonic synapses as a mechanism for global learning in spiking neural networks. A Leaky Integrate-and-Fire (LIF) neuron model with reward-modulated synaptic plasticity is proposed, where synaptic weights are updated using a global reinforcement signal. The approach complements local plasticity rules such as STDP and supports integration into hybrid SNN-RL architectures. The model is implemented in Python 3.12 using a Euler-based numerical scheme. Learning is driven by a reward/penalty signal defined as the difference between target and actual spike counts. Simulation results demonstrate numerical stability, bounded weight dynamics, and effective adaptation of synaptic parameters. The findings confirm that hedonic learning is a promising framework for temporal signal processing and biologically inspired learning systems. The model provides high interpretability and can serve as a flexible testbed for studying global plasticity. Future work may include scaling to larger networks and analyzing the effects of noise and stochasticity.

Ներկայացվել է 25. 02. 2026 թ.
Գրախոսվել է 04. 05. 2026 թ.
Ընդունվել է տպագրության 27. 05. 2026 թ.