



The 9th International Conference in Deep Learning in Computational Physics  
July, 2-4, 2025 SINP MSU, Moscow, Russia



# Probabilistic Spiking Neural Network with Correlation-based Memristive Synaptic Update

Вероятностная спайковая нейронная сеть с основанным на корреляции мемристивным синаптическим обновлением

Dmitry Kunitsyn<sup>1,2</sup>, Alexander Sboev<sup>1,2</sup>, Yury Davydov<sup>1</sup>, Danila Vlasov<sup>1</sup>, Alexey Serenko<sup>1</sup> and Roman Rybka<sup>1,2</sup>  
(1) National Research Centre “Kurchatov Institute”, Moscow, Russia  
(2) National Research Nuclear University MEPhI (Moscow Engineering Physics Institute), Moscow, Russia

Докладывает: Куницын Дмитрий

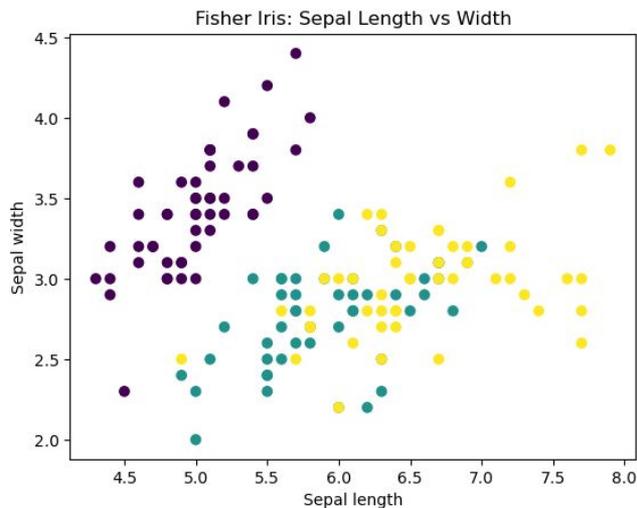
# Актуальность и цель

Спайковые нейронные сети (SNN) — это биологически вдохновленные модели, которые представляют информацию в виде дискретных последовательностей импульсов (спайков), что позволяет выполнять энергоэффективные вычисления на нейроморфных устройствах.

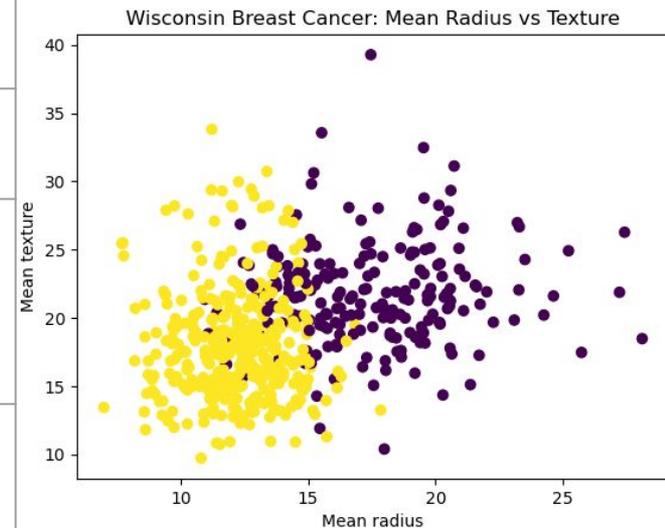
Создание робастных методов обучения спайковых сетей, реализуемых на нейроморфных платформах, открывает путь к энергоэффективным, масштабируемым и адаптивным вычислительным системам, устойчивым к шумам и динамике среды.

**Цель:** Разработать экономичную спайковую нейросеть для задач классификации с локальным корреляционным обучением, оптимизированную для аппаратной реализации на нейроморфных платформах.

# Наборы данных



Name	#features	#samples	#classes
Fisher Iris	4	150	3
Wisconsin Breast Cancer	30	569	2
Sklearn Digits	64	1797	10

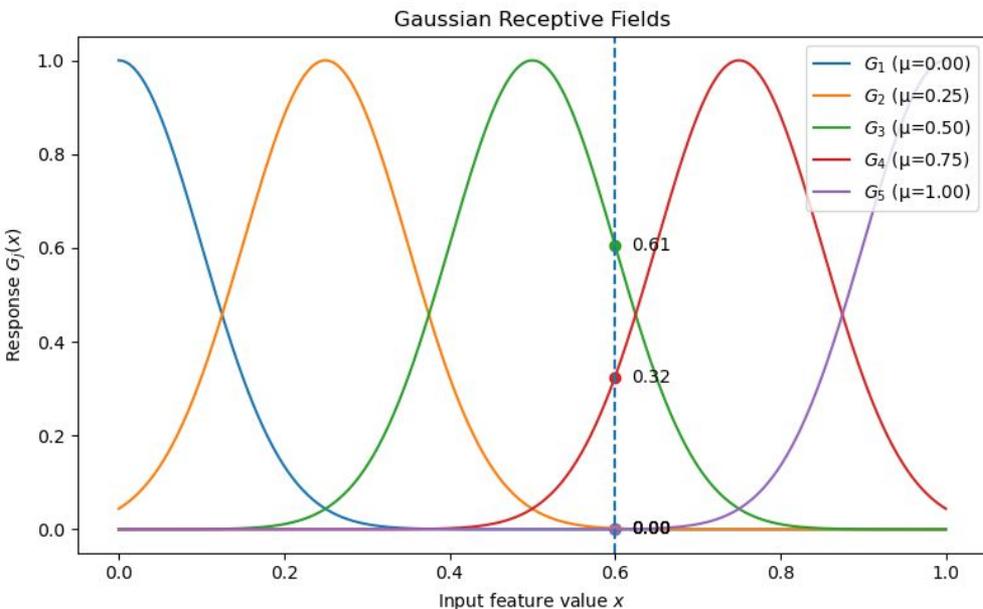


Samples from sklearn-digits



# Методы | Предварительная обработка

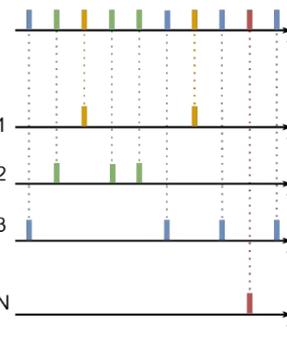
1. Гауссовы рецептивные поля (GRF) расширяют пространство признаков: каждый скалярный вход преобразуется в вектор откликов нескольких гауссиан.
2. L1-нормализация применяется для пропорционального распределения всех спайков из эталонной выходной спайковой последовательности по входным.



Входной вектор после  
**GRF**

$$\vec{F} = \begin{bmatrix} F_1 \\ F_2 \\ F_3 \\ \vdots \\ F_n \end{bmatrix} \begin{array}{l} \#spikes \propto F_1 \\ \#spikes \propto F_2 \\ \#spikes \propto F_3 \\ \\ \#spikes \propto F_n \end{array}$$

Эталонная спайковая  
последовательность



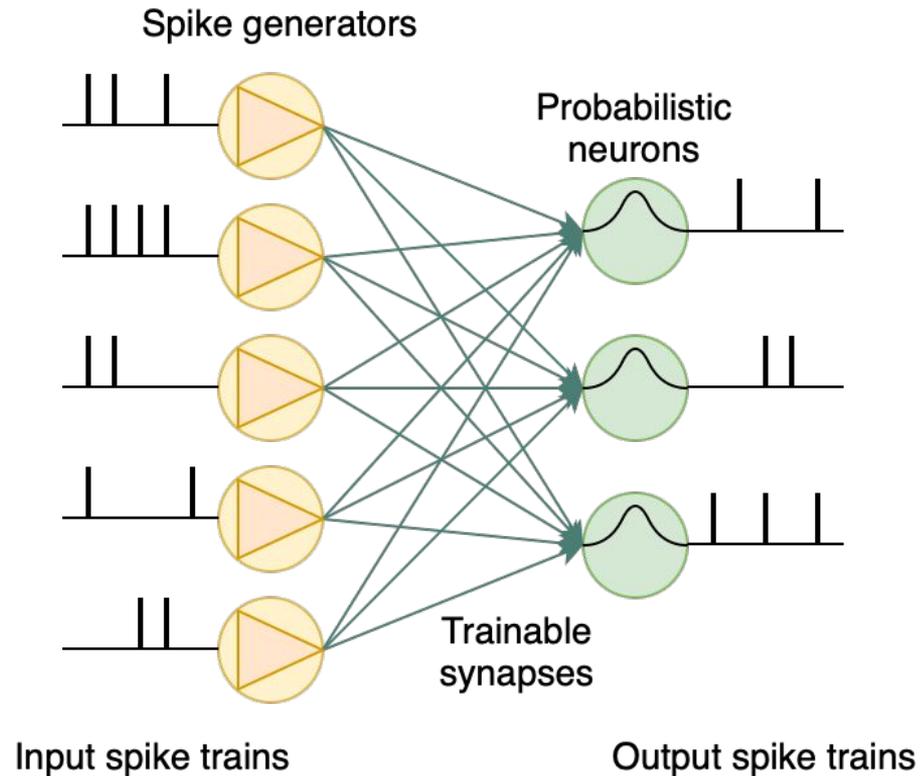
Закодированные  
в спайки  
признаки

Пуассоновское частотное кодирование используется для представления входных признаков.

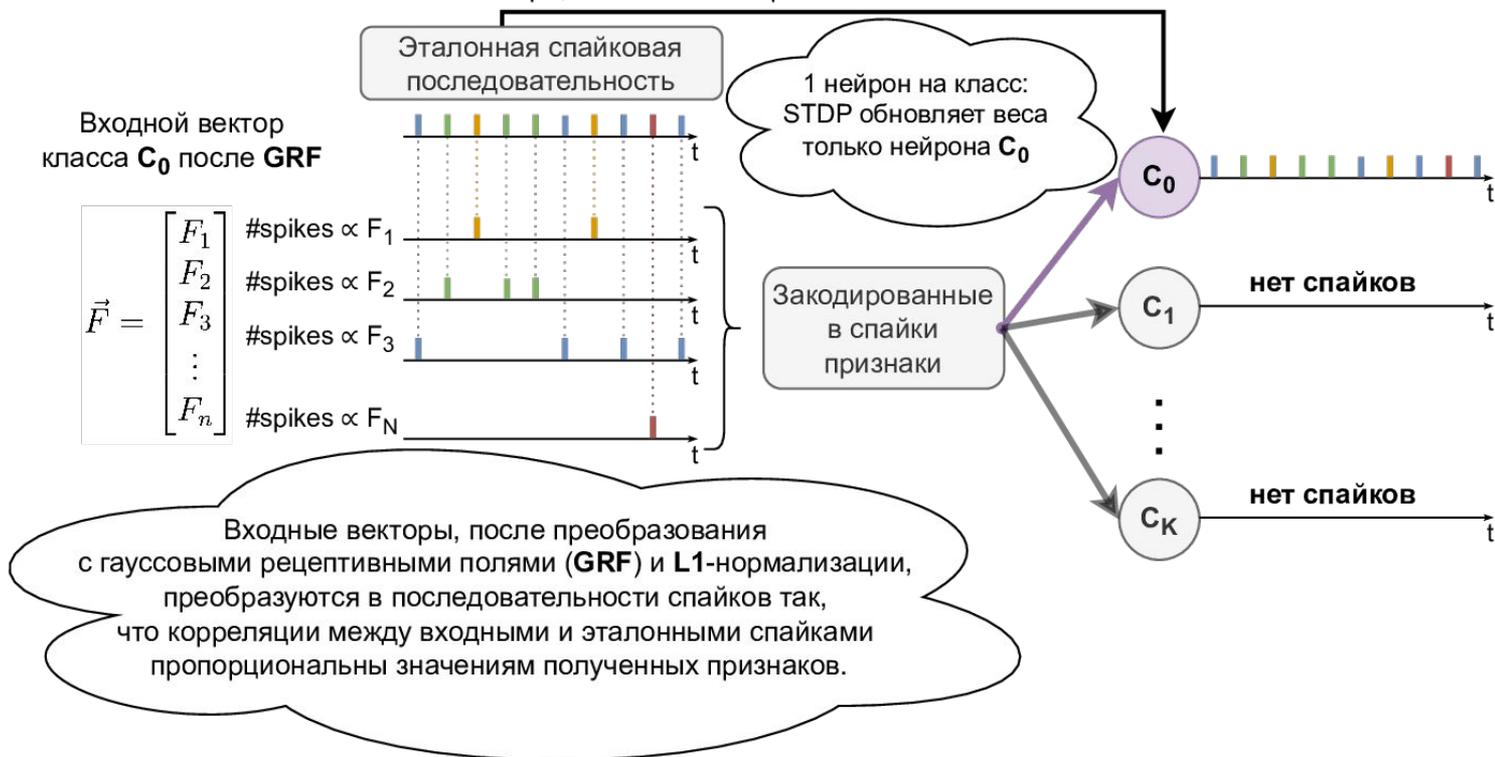
Поскольку STDP обновляет веса по корреляции пре- и постсинаптических спайков, предлагается следующий метод обучения:

1. Генерируется эталонная пуассоновская спайковая последовательность, отражающая пре- и постсинаптическую активность;
2. Спайки из эталона распределяются по входным признакам пропорционально их значениям;
3. Мемристивный STDP обновляет синаптические веса в зависимости от корреляции входных спайковых последовательностей с эталонной.

Генераторы спайков передают сгенерированные спайковые последовательности выходным нейронам по локально обучаемым синапсам.



Во время обучения с помощью стимуляции переменным током спайки из эталонной последовательности испускает только выходной нейрон, соответствующий классу входного вектора; остальные нейроны остаются неактивными.



# Методы | Классический и мемристовый STDP

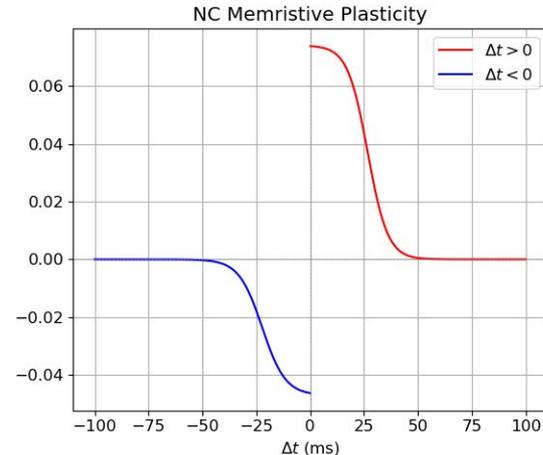
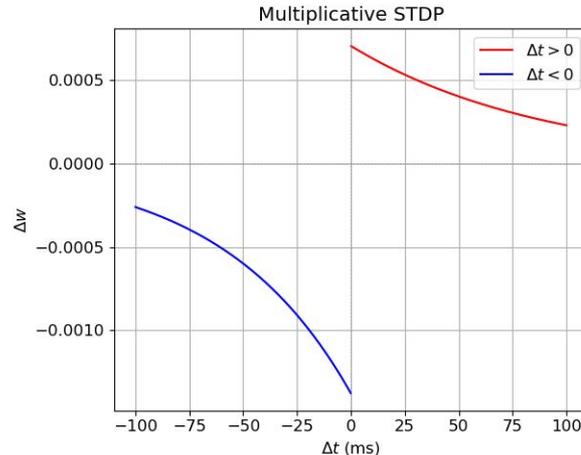
Для обучения использовалось 2 варианта пластичности:

- мультипликативный STDP с ограниченной симметричной схемой сопряжения пост-синаптических спайков с ближайшими пре-синаптическими спайками.

$$\Delta w(\Delta t) = \begin{cases} A^+ \cdot e^{-\frac{\Delta t}{\tau^+}}, & \text{при } \Delta t > 0, \\ A^- \cdot e^{\frac{\Delta t}{\tau^-}}, & \text{при } \Delta t < 0. \end{cases}$$

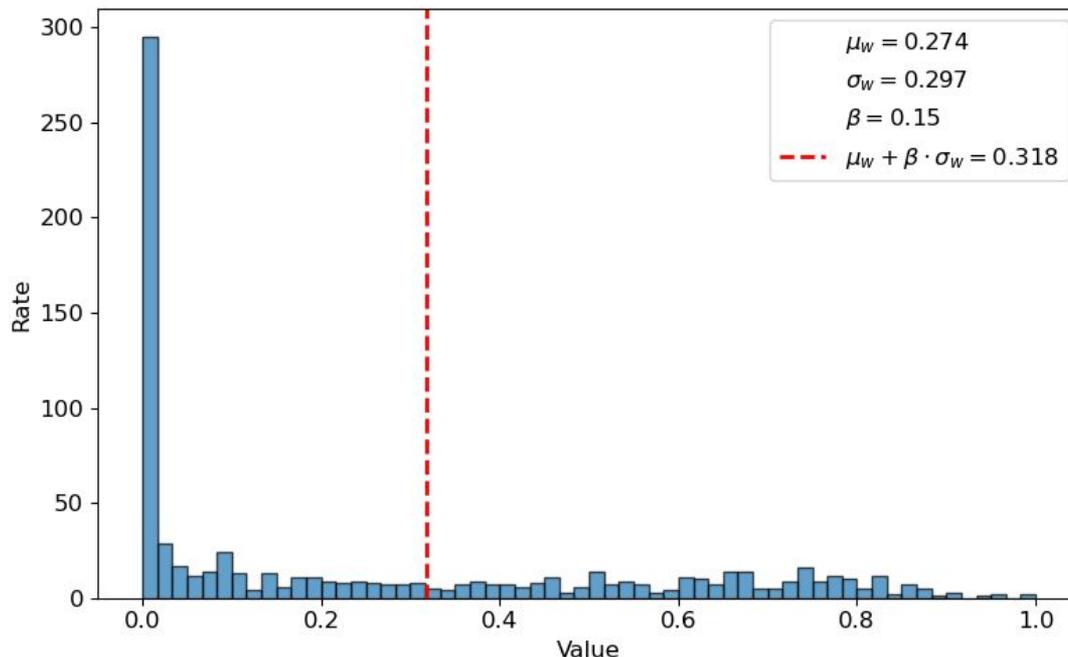
- Нанокompозитная мемристорная пластичность, моделируемая на основе экспериментальных данных соответствующего мемристора, где  $A^+ = 0.074$ ,  $A^- = -0.047$ ,  $\mu^+ = 26.7$  мс,  $\mu^- = -22.3$  мс,  $\tau^+ = 9.3$  мс,  $\tau^- = 10.8$  мс.

$$\Delta w(\Delta t) = \begin{cases} A^+ \cdot w \cdot \left[ 1 + \tanh\left(\frac{-\Delta t - \mu^+}{\tau^+}\right) \right], & \text{при } \Delta t > 0; \\ A^- \cdot w \cdot \left[ 1 + \tanh\left(\frac{\Delta t - \mu^-}{\tau^-}\right) \right], & \text{при } \Delta t < 0. \end{cases}$$



После обучения веса нейронов обрезаются и нормируются:

- Вычисляются среднее значение  $\mu_w$  и стандартное отклонение  $\sigma_w$  положительных весов.
- Веса, которые меньше порога  $\mu_w + \beta \cdot \sigma_w$ , обнуляются, убирая слабо выраженные связи.
- Оставшиеся веса линейно нормируются в диапазон  $[0, 1]$ .



Чтобы исключить необходимость подбора порога нейронов как гиперпараметра модели, использовалась вероятностная модель спайкового нейрона. При этом точность модели с вероятностными нейронами оказалась сопоставима с точностью модели с пороговыми нейронами в пределах статистической погрешности.

Вероятность  $P$  генерации спайка постсинаптическим нейроном в момент времени  $t$  при условии поступления спайка от пресинаптического нейрона в момент  $t - \tau_{syn}$  равна синаптическому весу  $w_{pre,post}$  между ними. Эта модель задаётся уравнением 1, где  $\tau_{syn} = 1$  мс — синаптическая задержка.

$$P(s_{post}(t) = 1 \mid s_{pre}(t - \tau_{syn}) = 1) = w_{pre,post} \quad (1)$$

Поскольку кодирование гарантирует, что только один спайк может достигнуть выходного нейрона на каждом временном шаге, выходная спайковая последовательность  $S_1$  нейрона представляет собой сдвинутое подмножество эталона  $S_0$ .

Для оценки степени соответствия выходного паттерна эталонному вычисляется простая корреляция:

$$\hat{r} = \sum_t S_1(t - \tau_{syn}) \cdot S_0(t) \quad (2)$$

где  $t$  — временной шаг. Класс нейрона, соответствующий наибольшему значению корреляции, выбирается в качестве предсказания сети.

<b>Dataset</b>	<b>F1-Score (STDP)</b>	<b>F1-Score (Nanocomposite plasticity)</b>
<b>Fisher Iris</b>	<b>97% ± 2%</b>	<b>97% ± 2%</b>
<b>Wisconsin Breast Cancer</b>	<b>90% ± 2%</b>	<b>90% ± 4%</b>
<b>Sklearn Digits</b>	<b>88% ± 3%</b>	<b>88% ± 1%</b>

В данной работе представлен новый корреляционный подход к обучению спайковых нейронных сетей, основанный на локальных правилах пластичности.

Показано, что интеграция следующих компонентов:

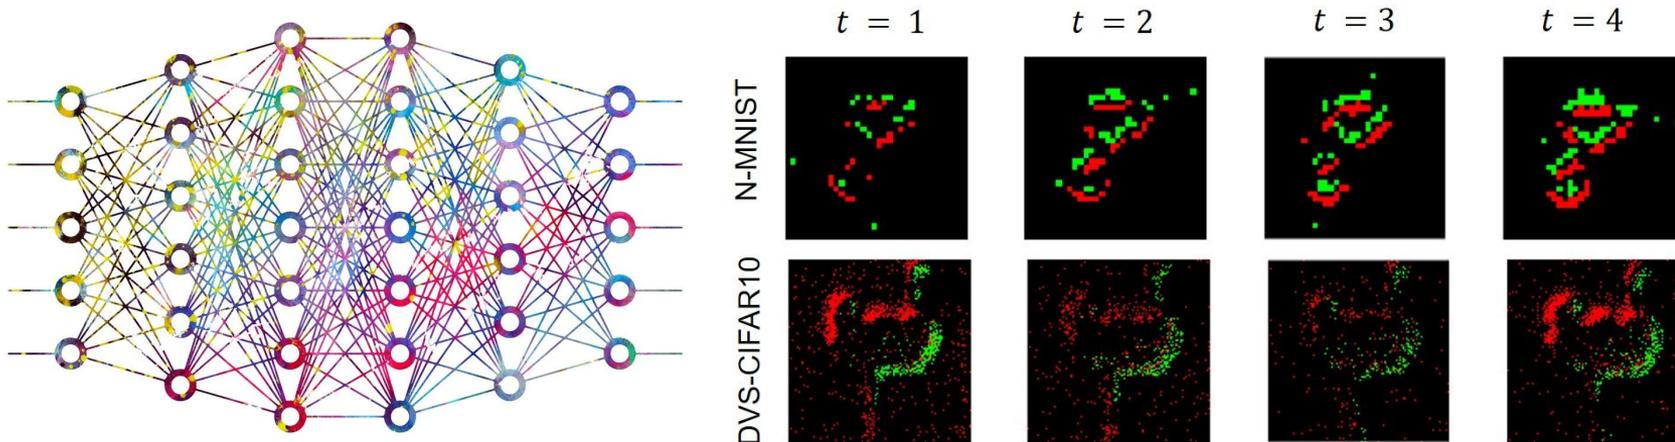
- ◇ вероятностной модели нейрона
- ◇ процесса кодирования и генерации пуассоновских спайковых последовательностей
- ◇ механизмов мемристорной пластичности

обеспечивает высокую точность при решении задач классификации, рассмотренных в исследовании.

# Дальнейшие исследования

Расширение предложенного корреляционного подхода для обучения многослойных спайковых нейронных сетей.

Применение метода к более сложным задачам, включая обработку нейроморфных данных, такие как N-MNIST, DVS-CIFAR10.



Благодарю за внимание!