

$$\tau_m \frac{du}{dt} = -[u(t) - u_{\text{rest}}] + RI(t)$$

$$t^{(f)} : u(t^{(f)}) = \vartheta$$

Нейроморфные вычисления: исследования и приложения

Николай Ильич Базенков

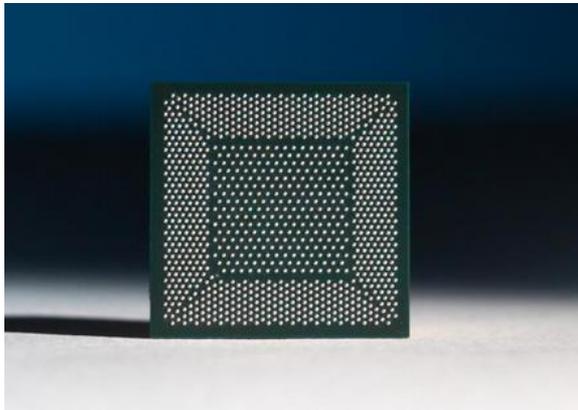
к.т.н., с.н.с. лаб. 11 ИПУ РАН

Ученый совет ИПУ РАН 17 октября 2022 г.

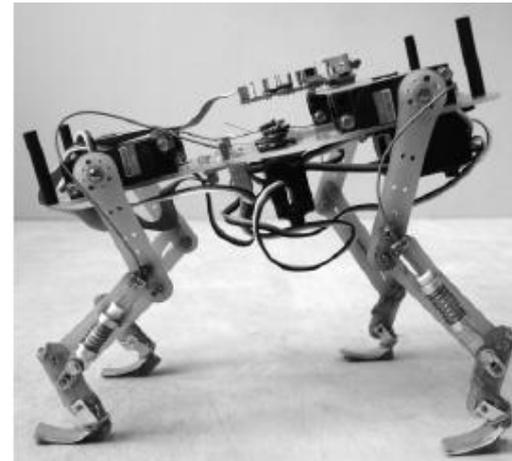
Что такое нейроморфные вычисления

Нейроморфные вычисления – имитация принципов работы мозга для решения вычислительных задач.

1. Аппаратные модели – самообучающиеся (on-chip learning) микросхемы, имитирующие сети биологических нейронов.
2. Программные модели – имитируют работу нервной системы на обычном компьютере.



Intel "Loihi" chip

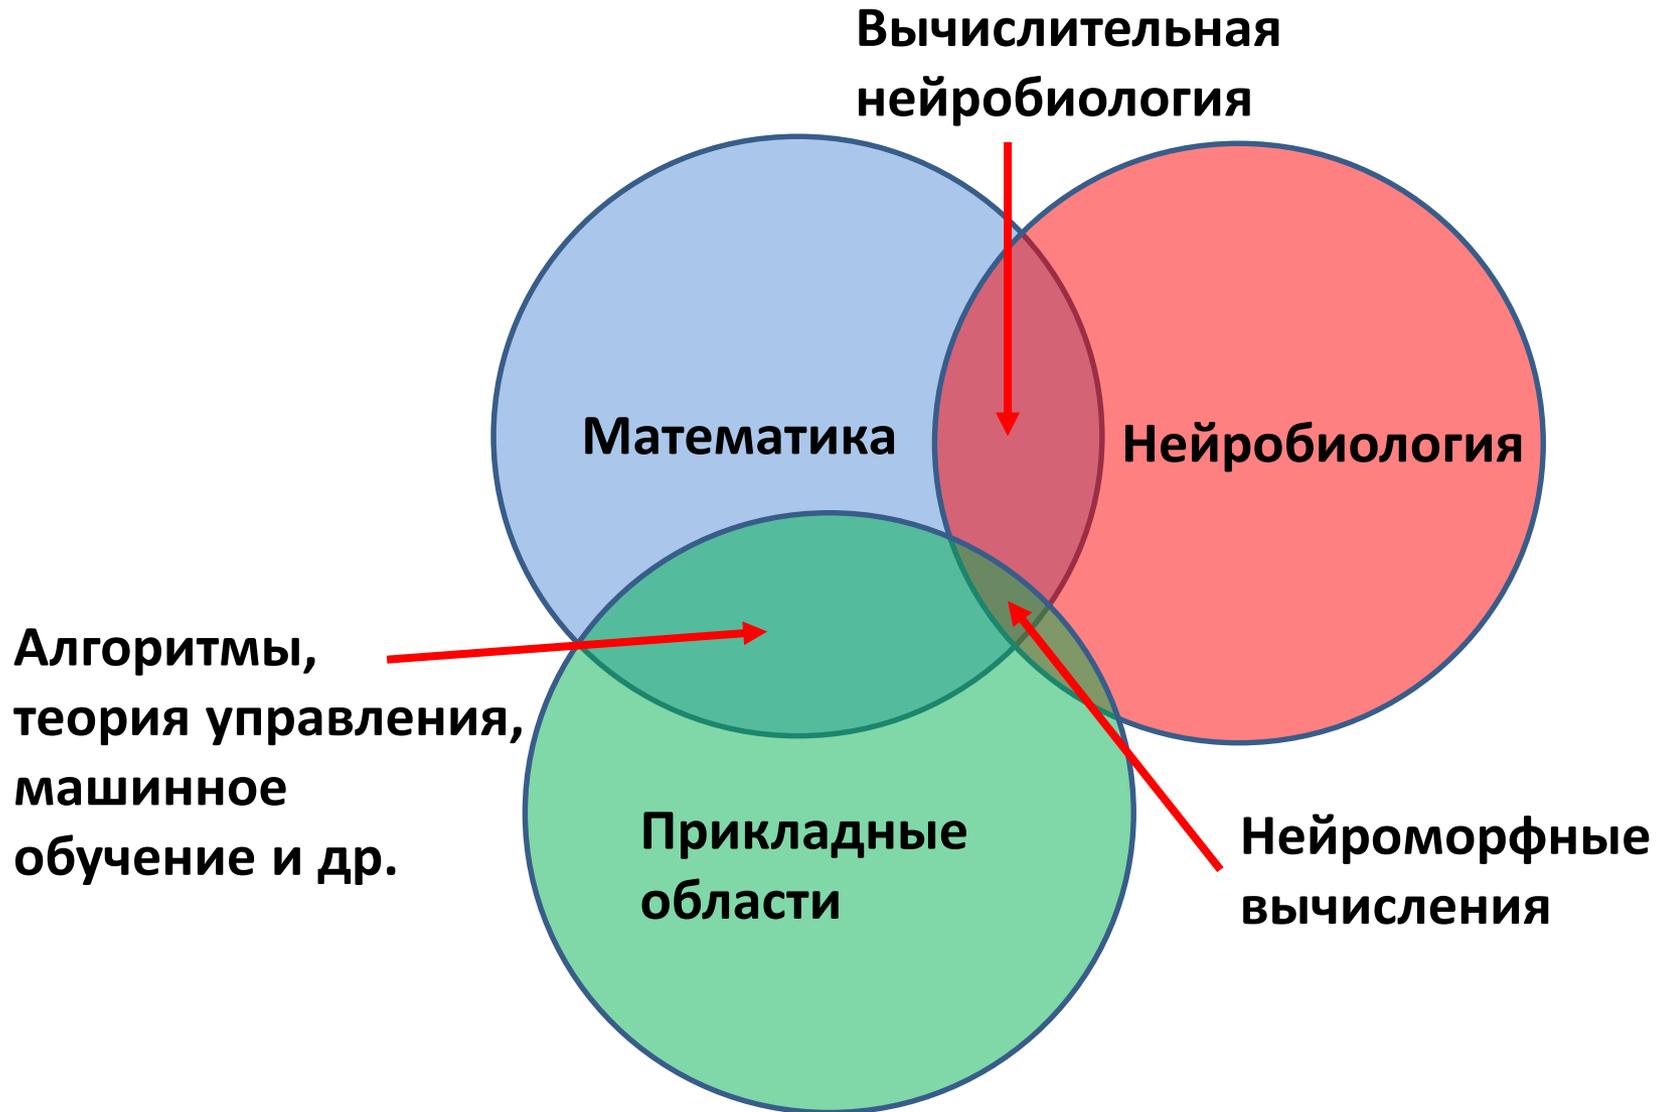


"Cheetah" quadruped robot

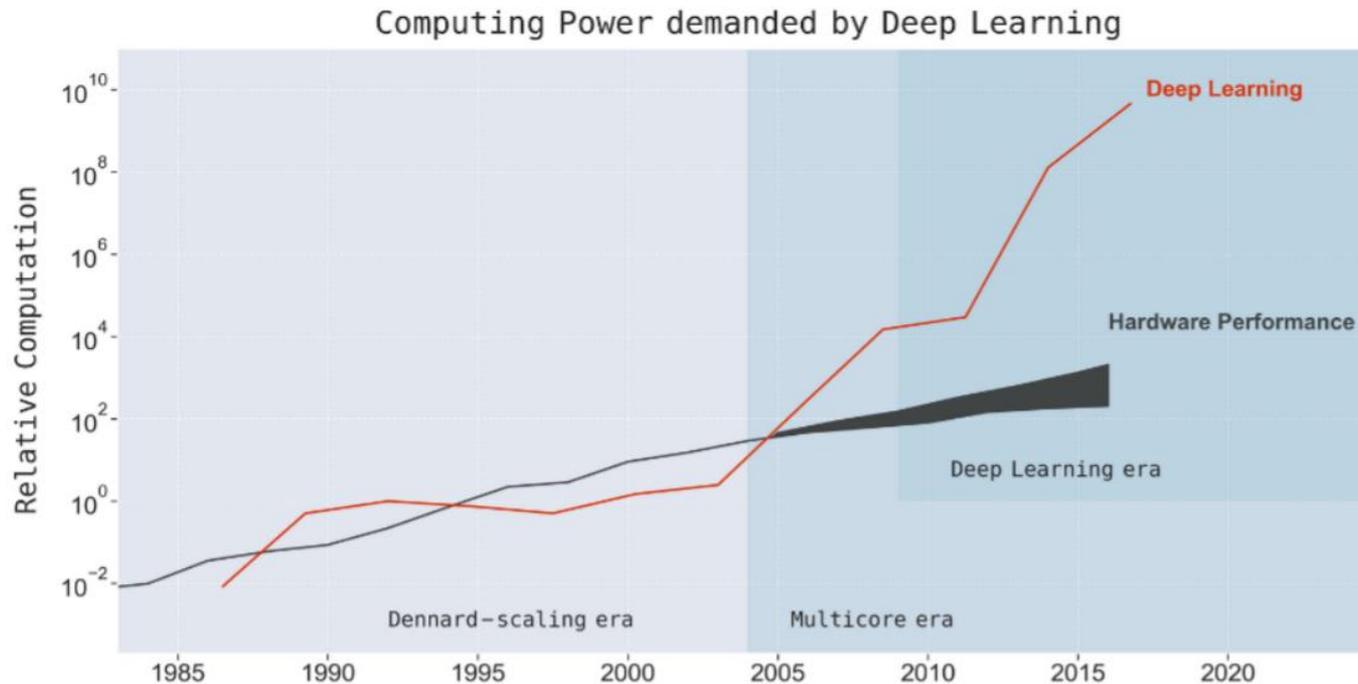
<https://www.intel.com/content/www/us/en/research/neuromorphic-computing.html>

Rutishauser, S. et.al. (2008). Passive compliant quadruped robot using central pattern generators for locomotion control. In *2008 2nd IEEE RAS & EMBS Int. Conf. Biomedical Robotics and Biomechatronics*

Что такое нейроморфные вычисления



Зачем это нужно?



- Размер нейросетей, используемых в глубоком обучении, увеличивается быстрее, чем растут вычислительные мощности
- Энергозатраты на обучение этих моделей на традиционной архитектуре фон Неймана колоссальны
- Большой интерес к поиску новых вычислительных архитектур

План доклада

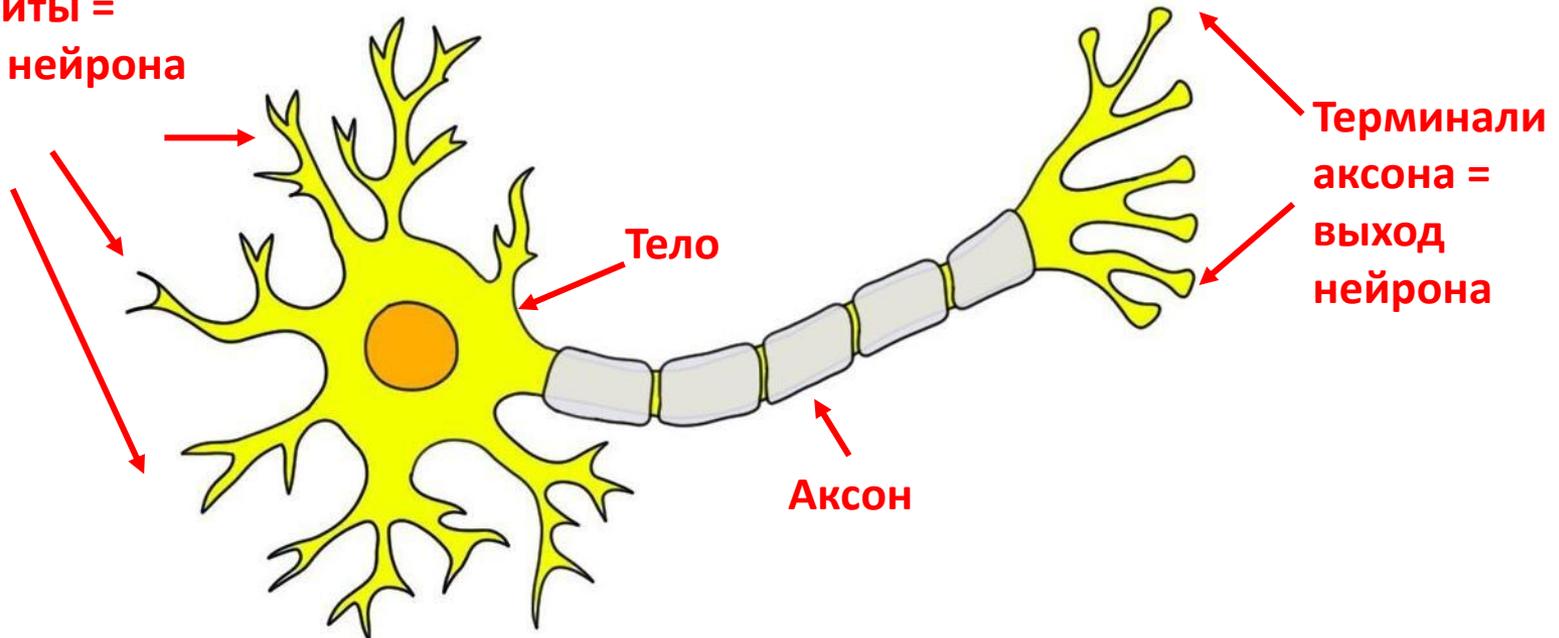
- 1. Спайковые нейросети**
2. Кодирование информации и обучение
3. Нейроморфные системы управления

Нейрон

Нейроны состоят из:

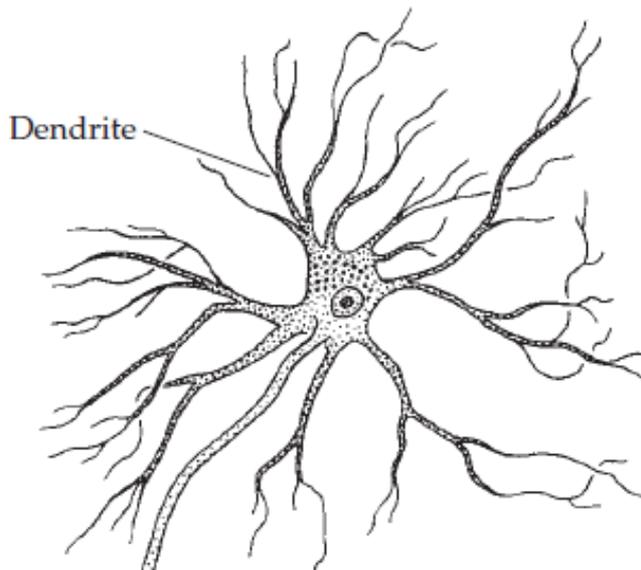
1. **Тела (сомы)**
2. **Дендритов**, которые принимают сигналы от других нейронов
3. **Аксона**, по которому сигнал распространяется к другим клеткам

**Дендриты =
входы нейрона**

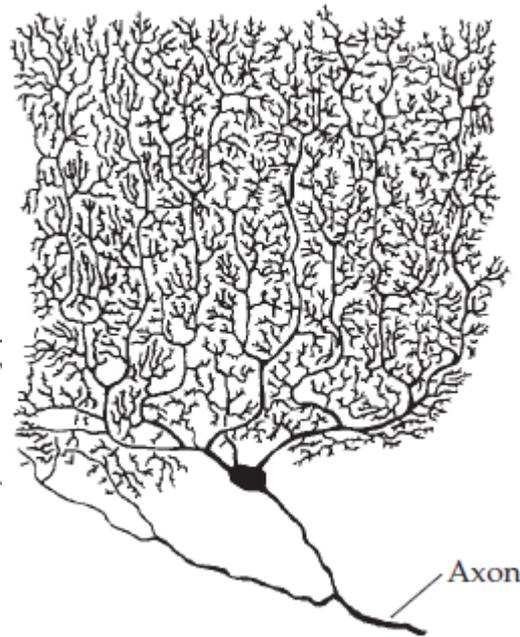


Разнообразие нейронов

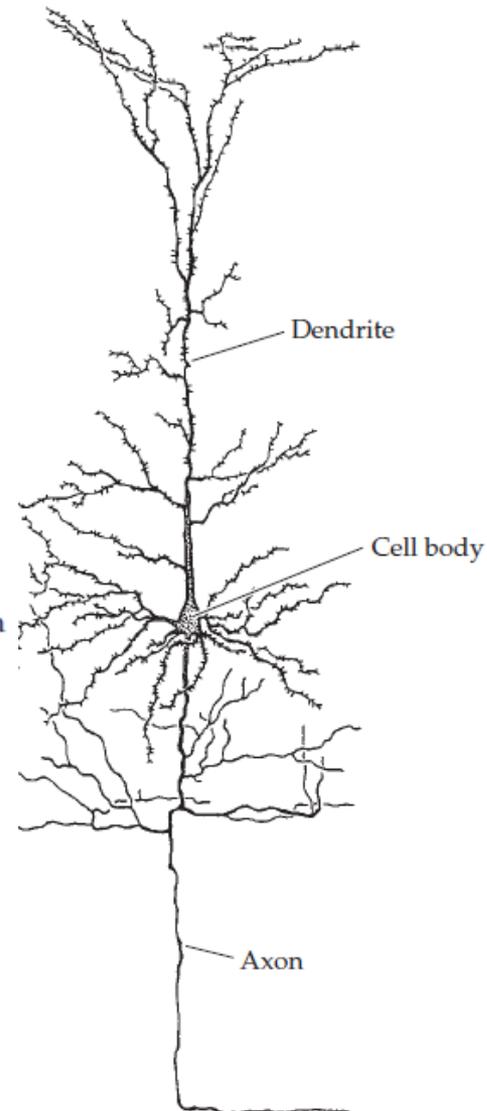
Motor neuron from spinal cord



Purkinje cell



Pyramidal cell from cortex



Нейроны на рисунках
Рамона-и-Кахаля (1852 – 1934)

<http://neuromorpho.org/>

Мембранный потенциал

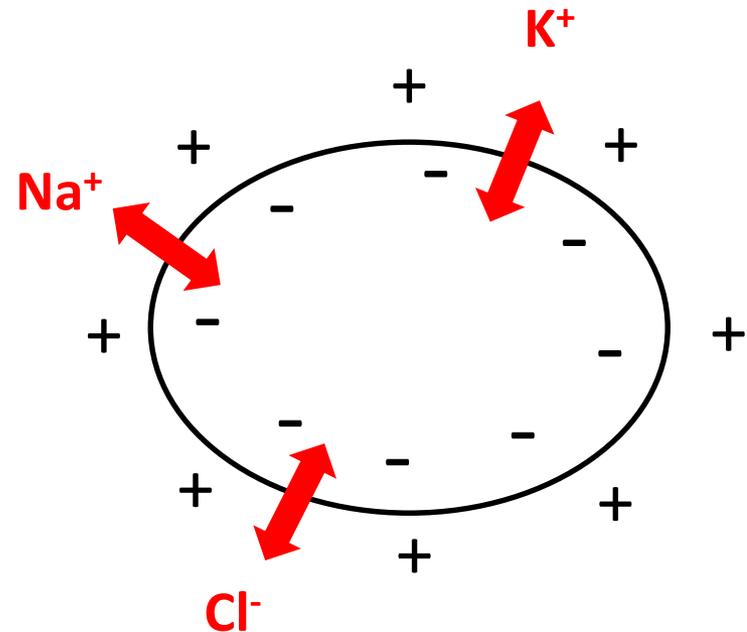
Мембрана – липидная оболочка, которая изолирует внутренности клетки от внешней среды.

Мембрана проницаема для некоторых ионов: K^+ , Na^+ , Cl^- , Ca^{2+}

Мембранный потенциал – электрический потенциал внутри мембраны по отношению к внешней среде.

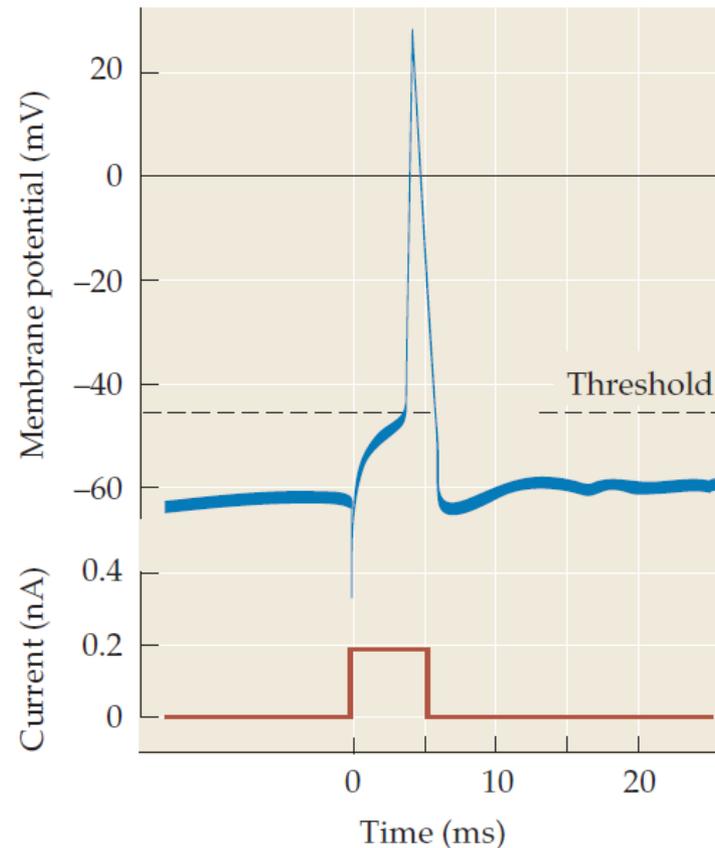
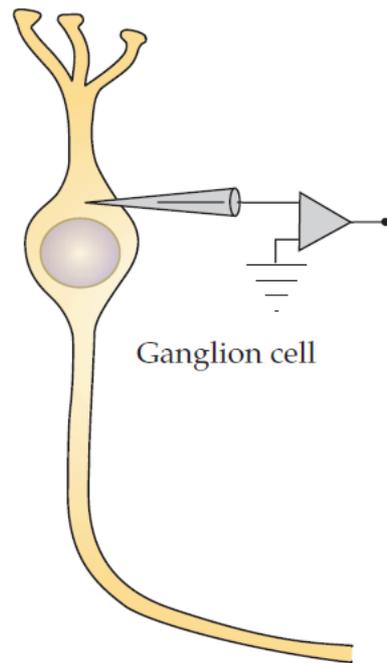
Потенциал покоя – мембранный потенциал нейрона при отсутствии внешних воздействий.

Отрицателен, от -70 до -40 мВ

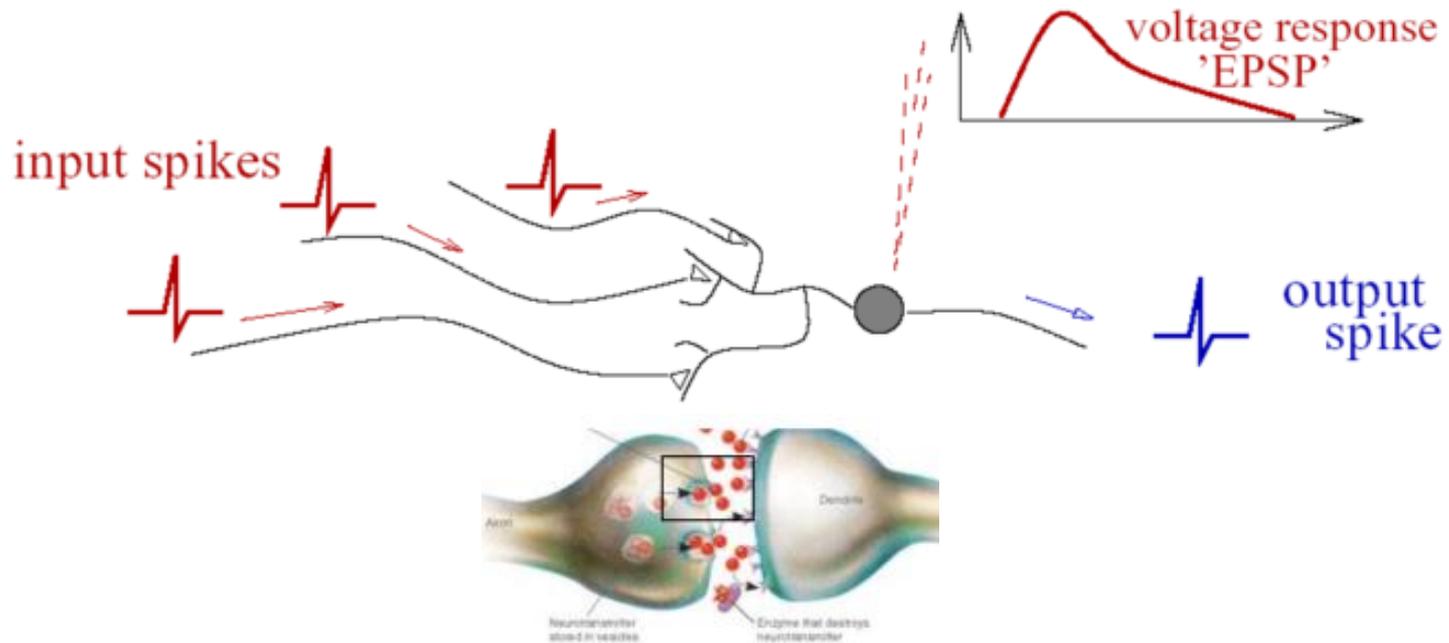


Сигналы в нервной системе

Потенциал действия (спайк) – «дискретный» нервный импульс, возникающий по принципу «все или ничего». ПД распространяется по аксону со скоростью около 120 м/с.



Синапсы



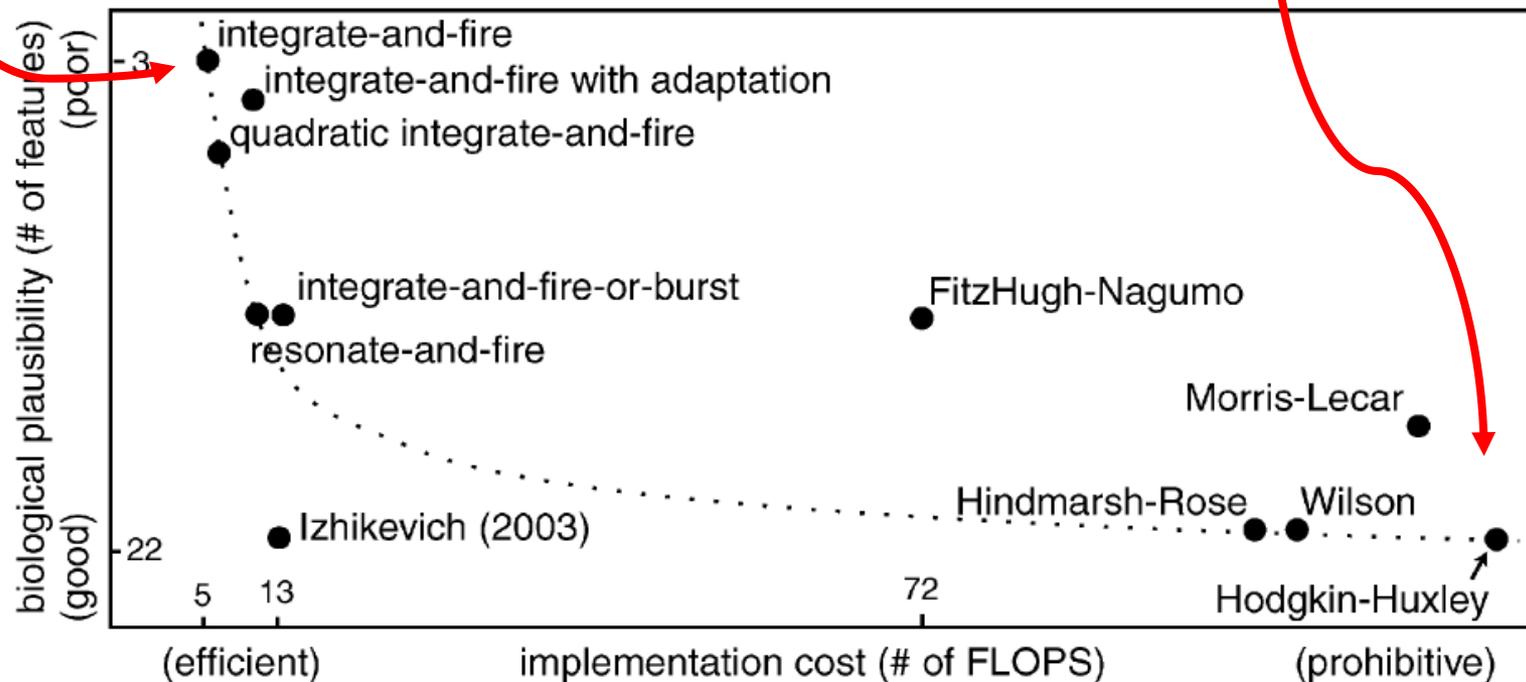
Синапс – соединение, с помощью которого один нейрон передает сигнал другому

Нейротрансмиттеры – химические вещества, которые высвобождаются в синапсе и, воздействуя на рецепторы мембраны, создают в ней локальный постсинаптический потенциал

Математические модели нейронов

Феноменологические модели – воспроизводят поведение, а не внутренние механизмы

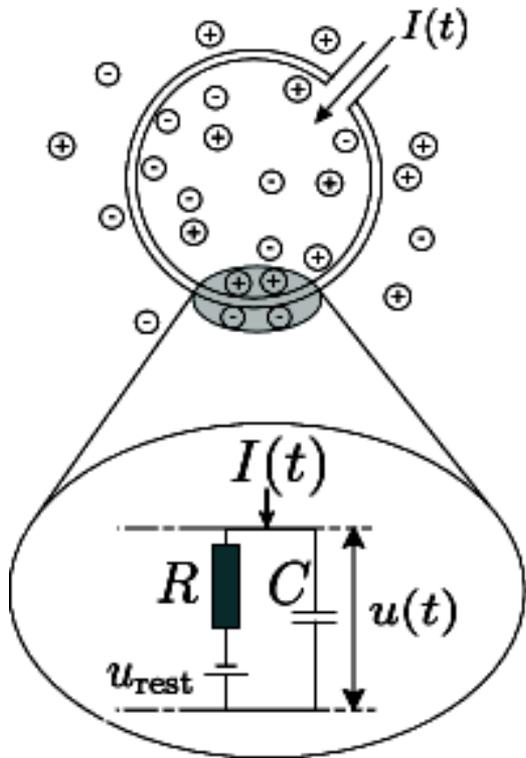
Биофизические модели – стараются точно воспроизвести механизмы работы нейрона



Izhikevich, E. M. (2003). Simple model of spiking neurons. IEEE Trans. on Neur. Networks

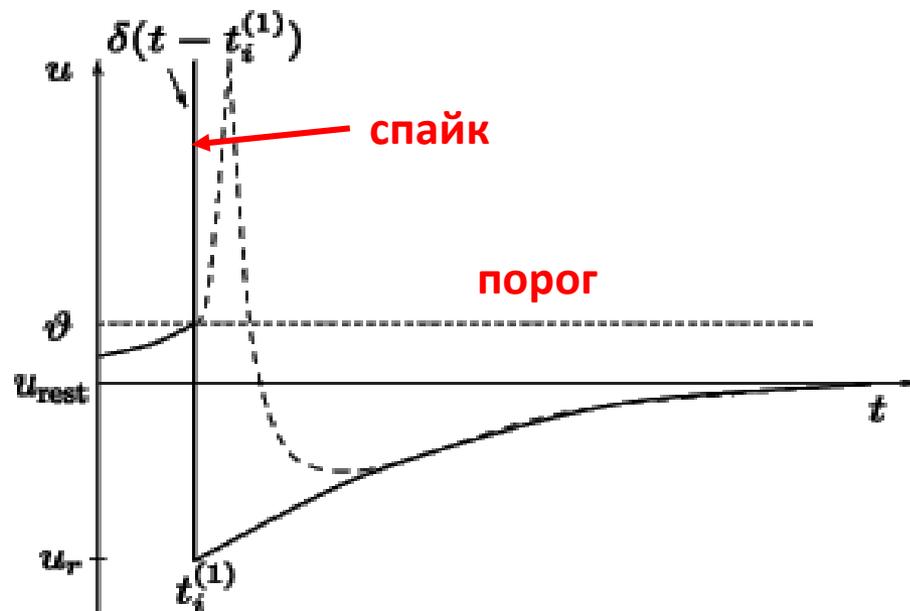
Модель Leaky Integrate and Fire

Уравнение пассивной мембраны с утечкой (RC-контур):



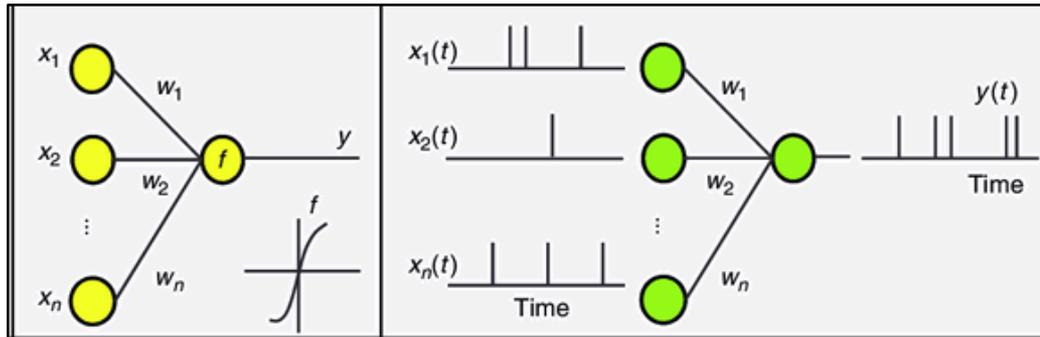
$$\tau_m \frac{du}{dt} = - [u(t) - u_{rest}] + R I(t) \quad (1)$$

$t^{(f)} : u(t^{(f)}) = \vartheta$ **условие возникновения спайка**



Спайковые нейронные сети

Искусственная нейронная сеть (ИНС)



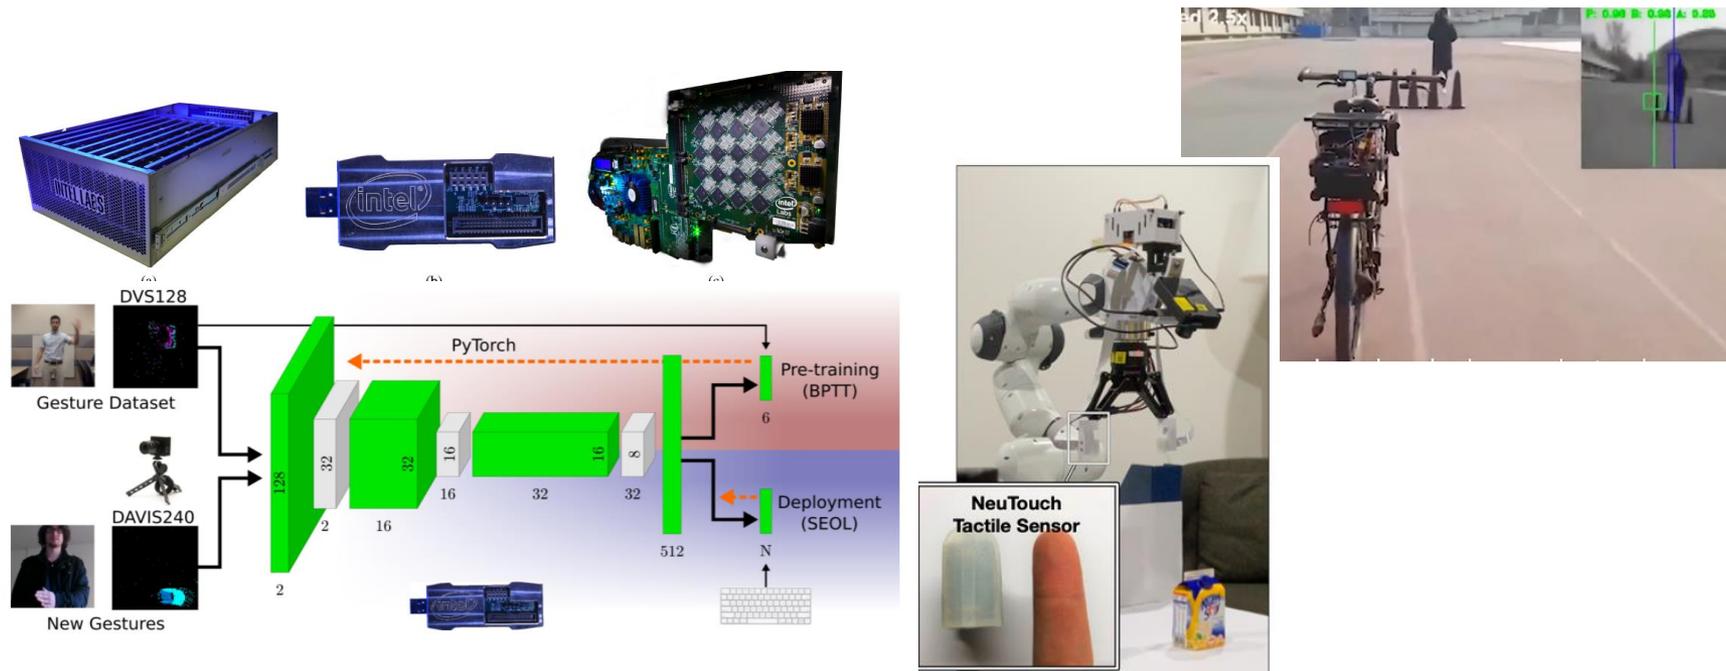
Искусственная нейронная сеть:

1. Входы и выход нейрона – вещественные числа
2. У нейрона нет состояния
3. Функция выхода нейрона дифференцируема
4. Функционирует в дискретном времени (по тактам)
5. Синхронный режим - за один такт вычисляются активации всех нейронов

Спайковая нейронная сеть:

1. Входы и выход нейрона – потоки дискретных событий (спайков)
2. У нейрона есть состояние (мембранный потенциал)
3. Выход нейрона не дифференцируем
4. Функционирует в непрерывном времени
5. Асинхронный режим – при появлении спайка обновляются только состояния обрабатывающих его нейронов

Нейроморфные процессоры



SpiNNaker 1,2 – исследовательский процессор. Эмуляция кортикальной колонки

IBM TrueNorth – первый промышленный чип: 4К ядер, 1М нейронов, 256М синапсов. Обучение происходит на внешнем GPU

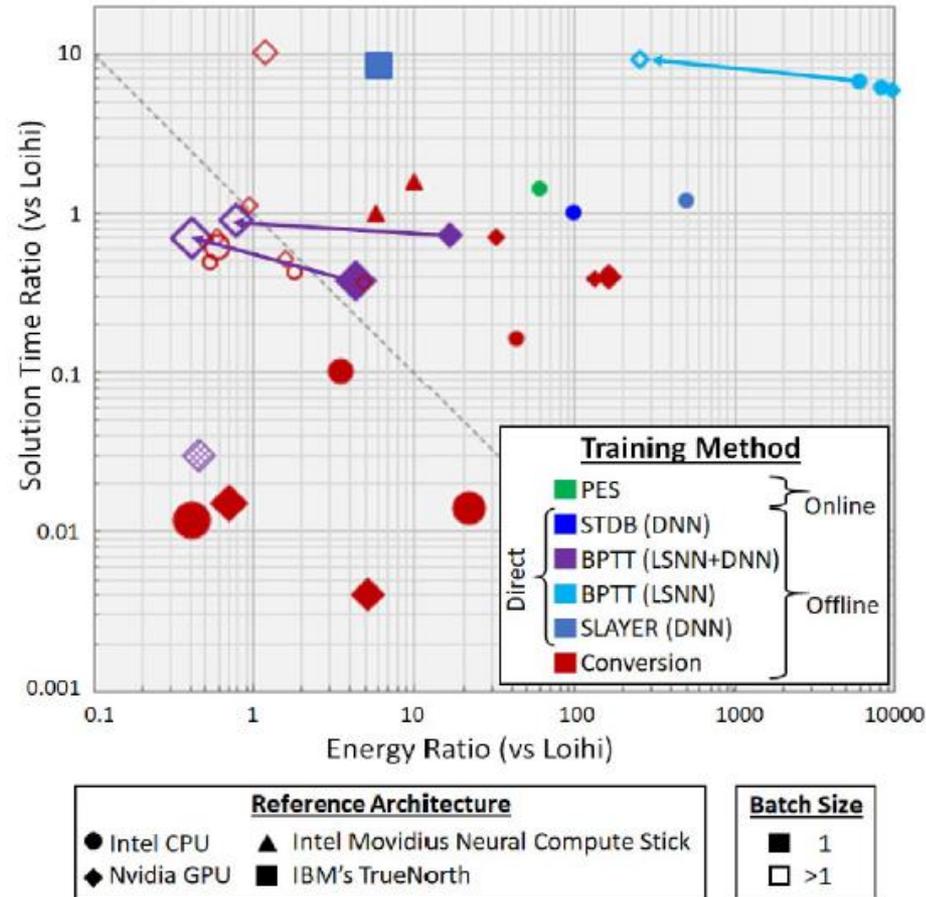
BrainScale 1,2 – аналоговый (ASIC), 512 нейронов, 114К синапсов + 2 CPU

Intel Loihi 2 - 128 ядер, 1М нейронов, 120М синапсов

Tianji (университет Синьхуа) – 156 ядер, 40К нейронов, 10М синапсов

Алтай (компания Мотив-НТ) – 256 ядер, 131К нейронов, 67К синапсов

Нейроморфные процессоры

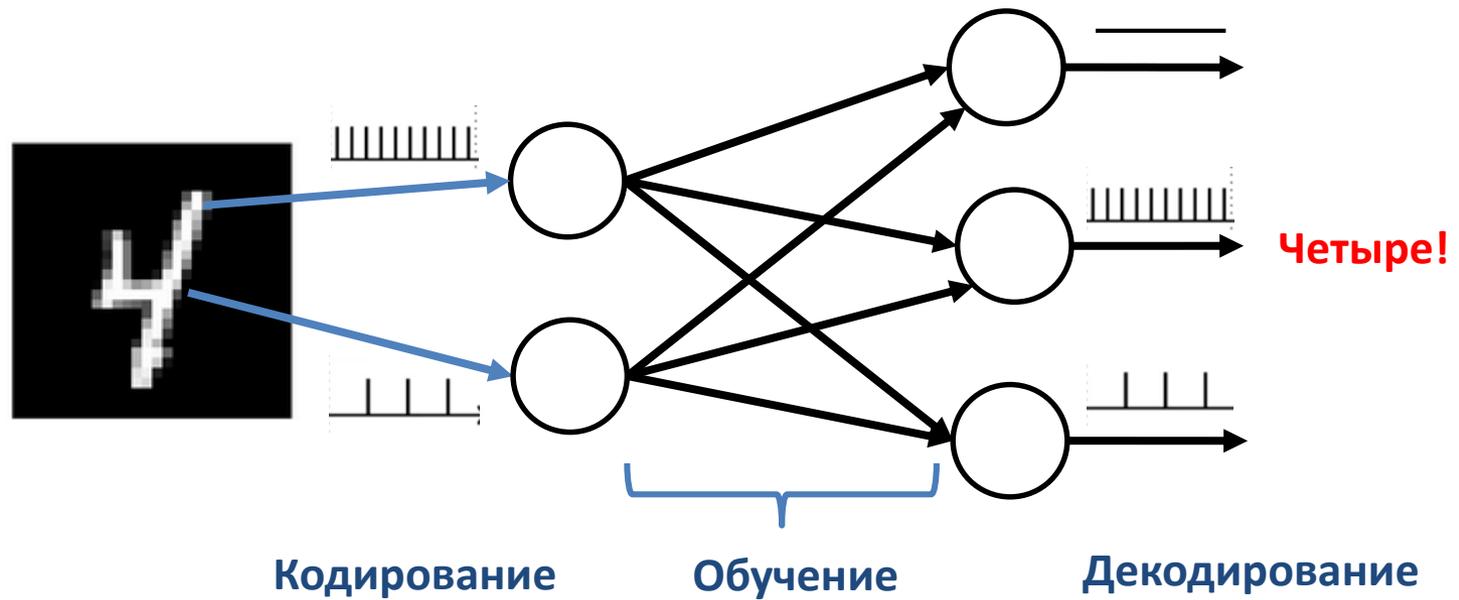


Davies, M., Wild, A., Orchard, G., Sandamirskaya, Y., Guerra, G. A. F., Joshi, P., ... & Risbud, S. R. (2021). Advancing neuromorphic computing with loihi: A survey of results and outlook. *Proceedings of the IEEE*, 109(5), 911-934.

План доклада

1. Спайковые нейросети
- 2. Кодирование информации и обучение**
3. Нейроморфные системы управления

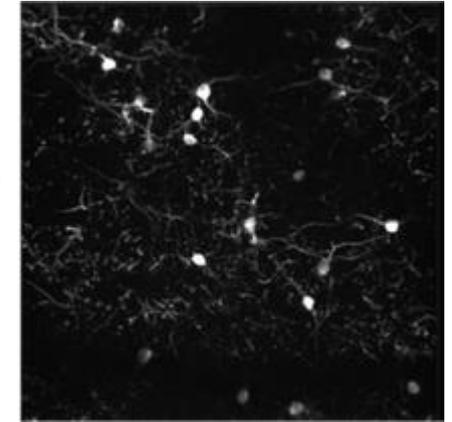
Кодирование и обучение



Проблема кодирования



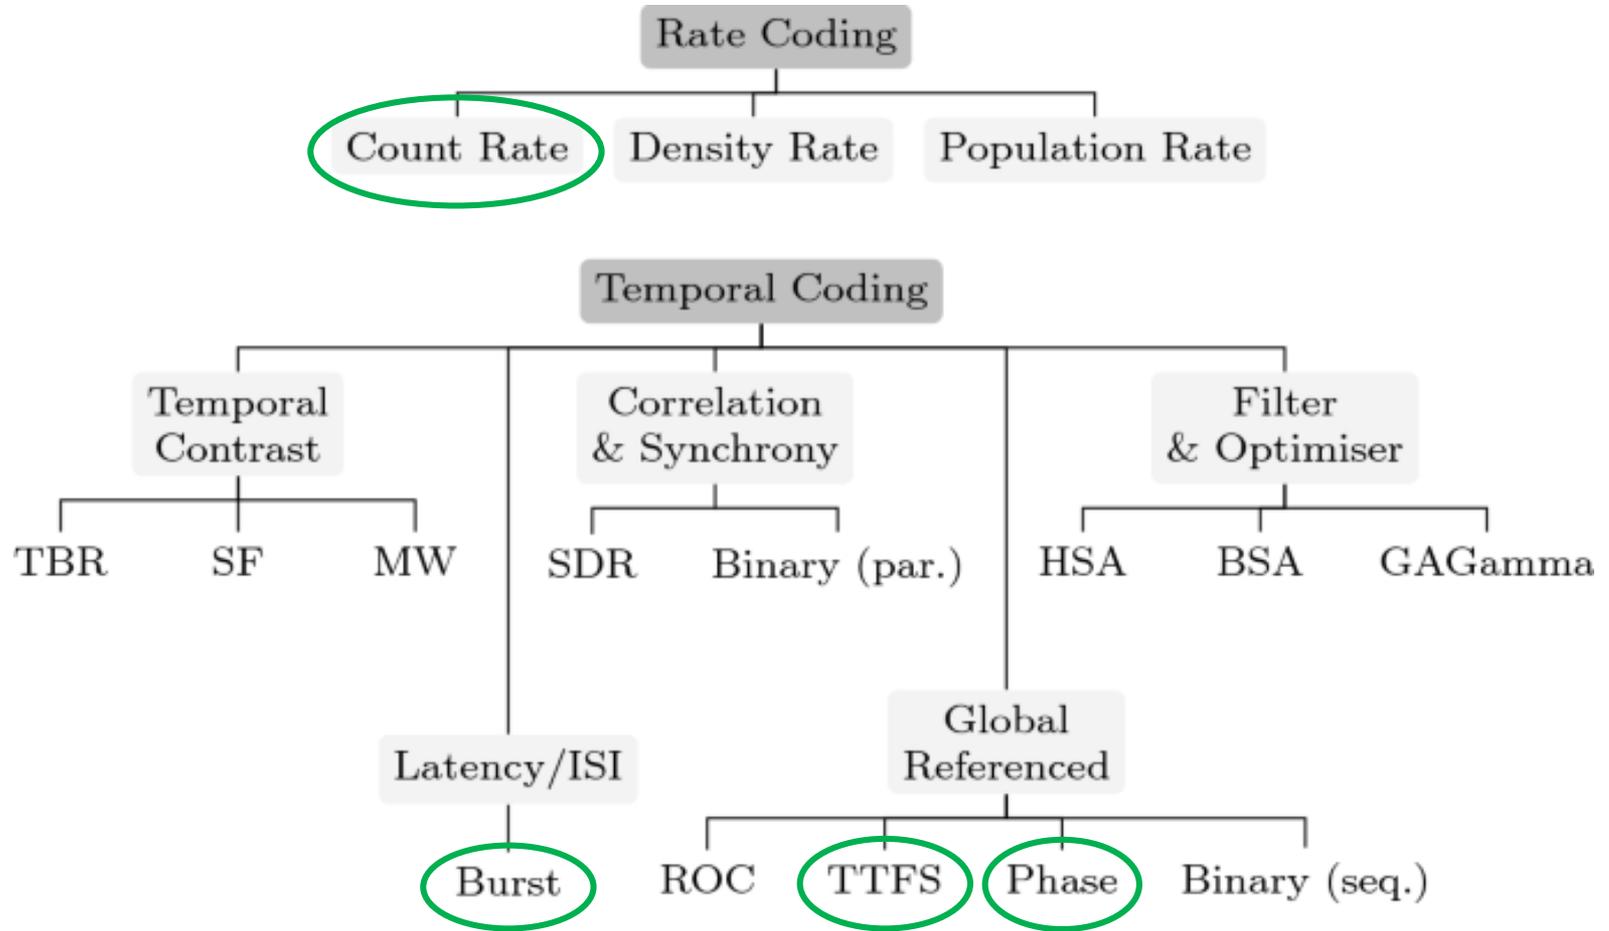
Входной образ



Активность нейронов

<https://observatory.brain-map.org/visualcoding/search/overview>

Разнообразие схем кодирования



Auge D. et al. A survey of encoding techniques for signal processing in spiking neural networks //Neural Processing Letters. – 2021. – T. 53. – No. 6. – C. 4693-4710.

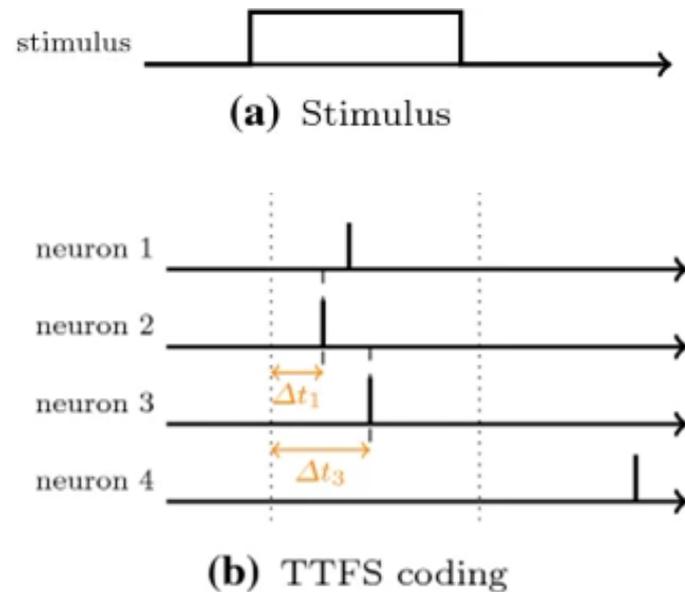
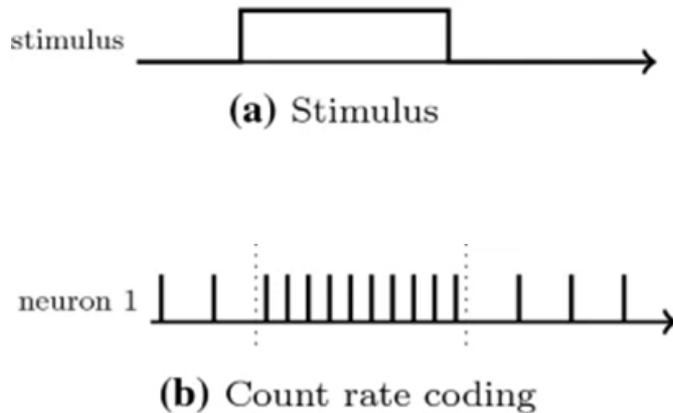
<https://link.springer.com/article/10.1007/s11063-021-10562-2>

Кодирование информации в СНС

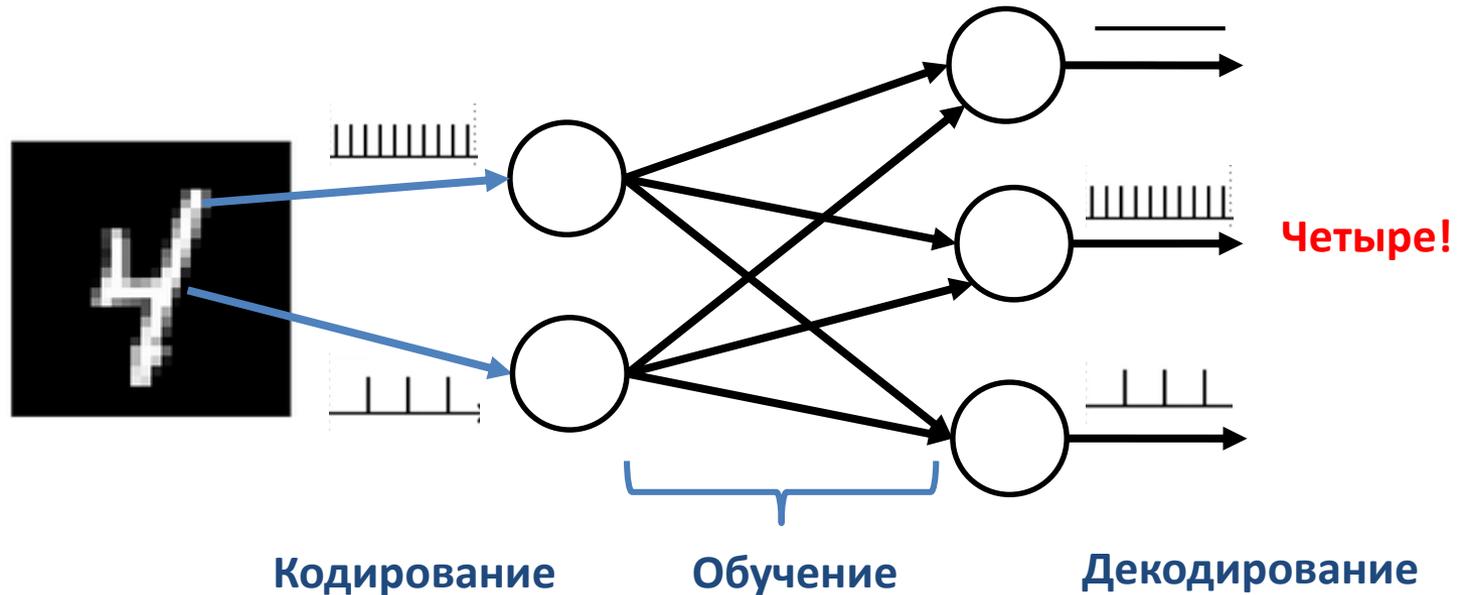
Частотное - частота спайков соответствует интенсивности стимула (яркости пикселя, амплитуде звука и т.д.)

Временное - свойства стимула кодируются временем прихода спайков.

Например, **TTFS – Time to First Spike**



Обучение СНС

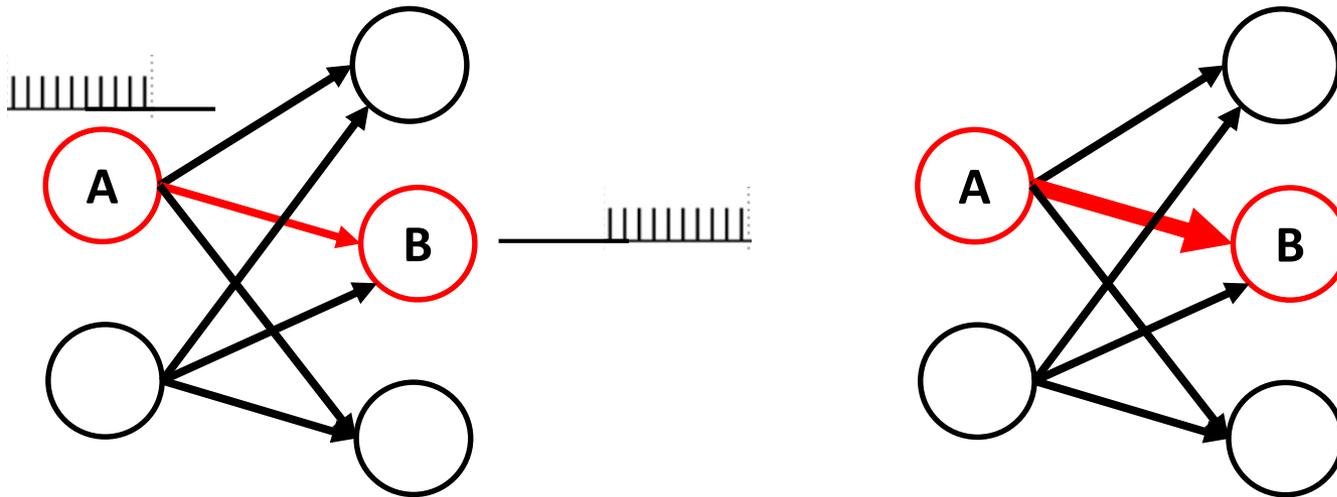


Методы обучения спайковых нейросетей

1. **Биологические** – имитируют принципы обучения живых нейронов, известные нейробиологам
2. **Градиентные** – преобразуют модель нейрона так, чтобы выход был дифференцируем. Затем применяются методы обучения ИНС
3. **Конверсия из ИНС** – обученная искусственная нейросеть конвертируется в спайковую

Биологические методы обучения

1. **Правило Хебба** – если активность нейронов связана, связь между ними усиливается
2. **Локальность** – сила связи не зависит от активности других нейронов в сети



STDP – Spike Timing Dependent Plasticity

1. Вес растет, если $t_A < t_B$
2. Вес уменьшается, если $t_A > t_B$

Изменение веса каждой связи описывается тремя уравнениями:

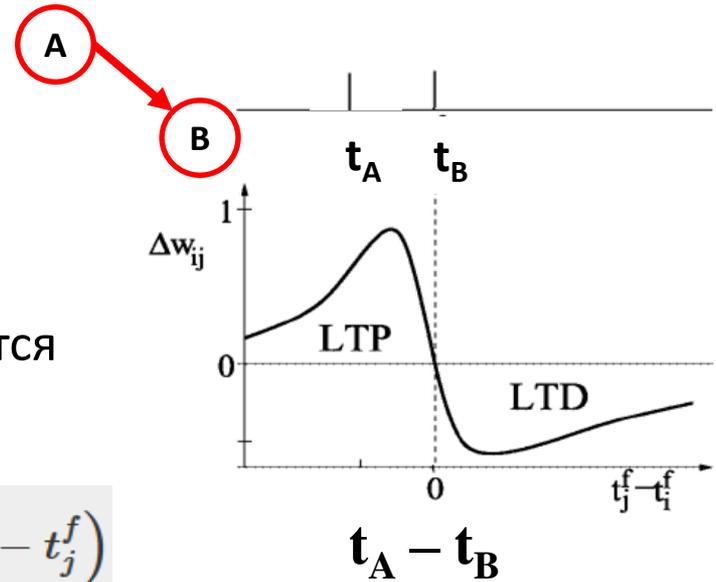
x_j – суммирует спайки **A**

$$\frac{d}{dt} x_j = -\frac{x_j}{\tau_+} + \sum_f \delta(t - t_j^f)$$

y_i – суммирует спайки **B**

$$\frac{d}{dt} y_i = -\frac{y_i}{\tau_-} + \sum_f \delta(t - t_i^f)$$

$$\frac{d}{dt} w_{ij}(t) = A_- (w_{ij}) y_i(t) \sum_f \delta(t - t_j^f) + A_+ (w_{ij}) x_j(t) \sum_f \delta(t - t_i^f)$$



Обучение сети методом STDP



Peter Udo Diehl

 FOLLOW

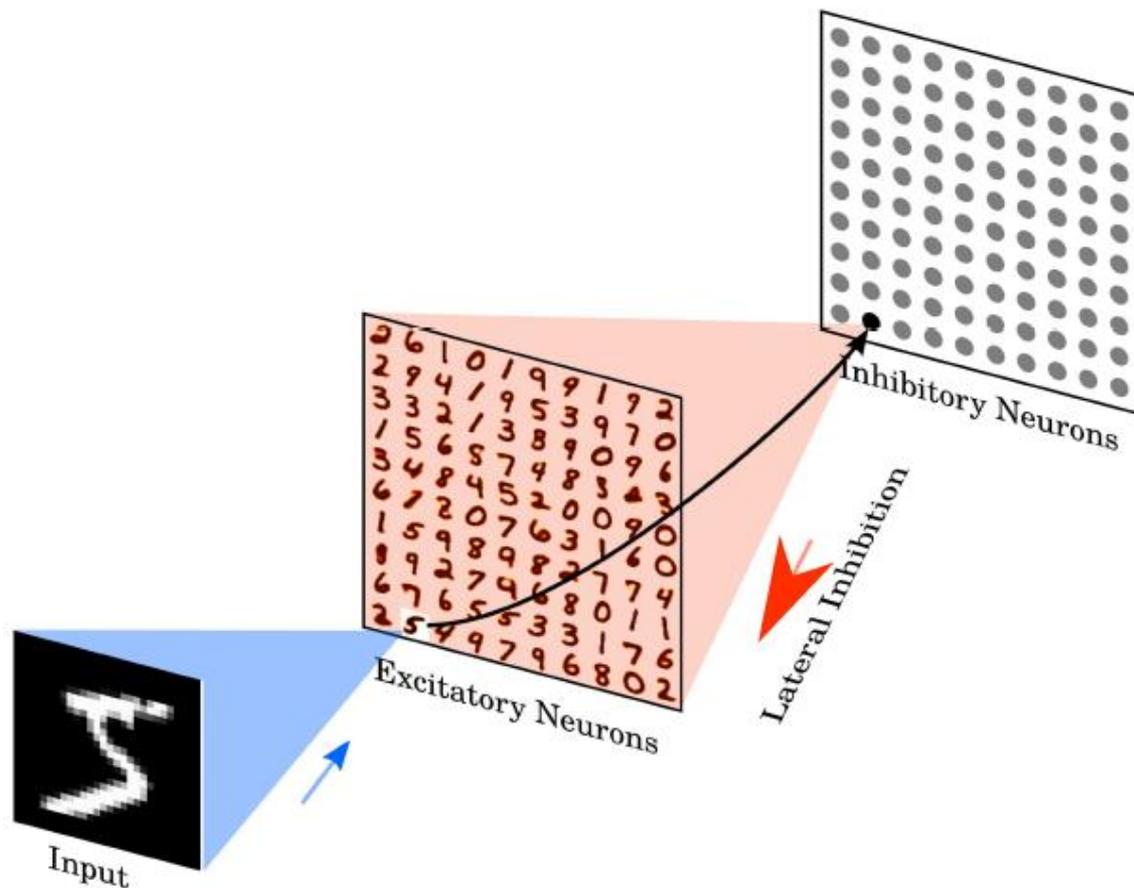
PhD, ETH Zürich

Verified email at audatic.ai - [Homepage](#)

[Deep Learning](#) [Artificial Intelligence](#) [Computational Neuroscience](#) [Audiology](#)
[Neuromorphic Computing](#)

TITLE	CITED BY	YEAR
Unsupervised Learning of Digit Recognition Using Spike-Timing-Dependent Plasticity PU Diehl, M Cook Frontiers in Computational Neuroscience	710	2015
Fast-Classifying, High-Accuracy Spiking Deep Networks Through Weight and Threshold Balancing PU Diehl, D Neil, J Binas, M Cook, SC Liu, M Pfeiffer IEEE International Joint Conference on Neural Networks (IJCNN)	541	2015
Conversion of Artificial Recurrent Neural Networks to Spiking Neural Networks for Low PU Diehl, G Zarrella, A Cassidy, BU Pedroni, E Neftci arXiv	424 *	2016
Conversion of Artificial Recurrent Neural Networks to Spiking Neural Networks for Low-power Neuromorphic Hardware PU Diehl, G Zarrella, A Cassidy, BU Pedroni, E Neftci arXiv	121	2016

Обучение сети методом STDP



Diehl, P. U., & Cook, M. (2015). Unsupervised learning of digit recognition using spike-timing-dependent plasticity. *Frontiers in computational neuroscience*, 9, 99. <https://github.com/peter-u-diehl/stdp-mnist>

ЭФФЕКТИВНОСТЬ

TABLE 1 | Classification accuracy of spiking neural networks on MNIST test set.

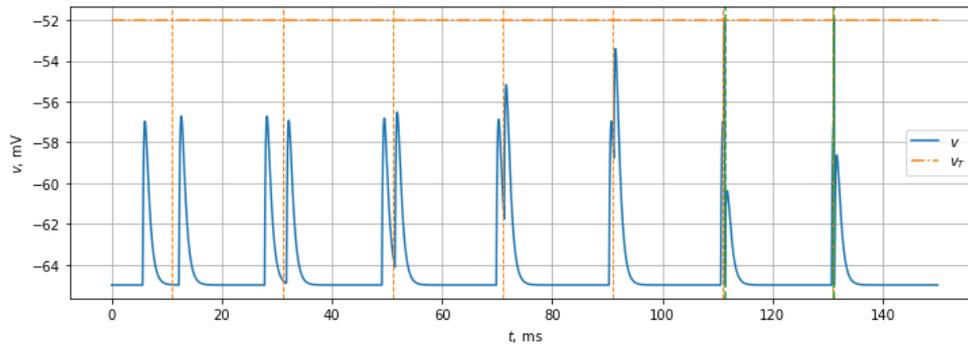
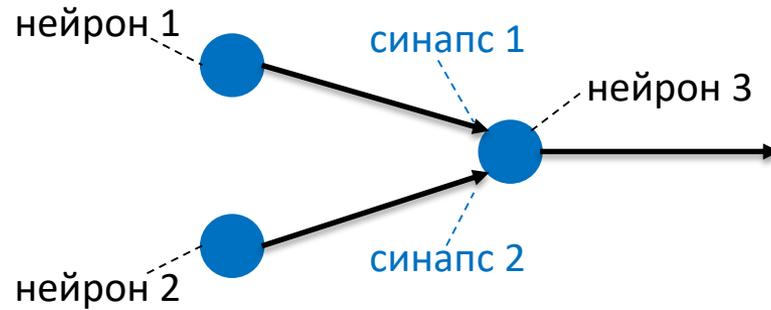
Architecture	Preprocessing	Training-type	(Un-)supervised	Learning-rule	Performance
Dendritic neurons (Hussain et al., 2014)	Thresholding	Rate-based	Supervised	Morphology learning	90.3%
Spiking RBM (Merolla et al., 2011)	None	Rate-based	Supervised	Contrastive divergence, linear classifier	89.0%
Spiking RBM (O'Connor et al., 2013)	Enhanced training set to 120,000 examples	Rate-based	Supervised	Contrastive divergence	94.1%
Spiking convolutional neural network (Diehl et al., 2015)	None	Rate-based	Supervised	Backpropagation	99.1%
Spiking RBM (Neftci et al., 2013)	Thresholding	Rate-based	Supervised	Contrastive divergence	92.6%
Spiking RBM (Neftci et al., 2013)	Thresholding	Spike-based	Supervised	Contrastive divergence	91.9%
Spiking convolutional neural network (Zhao et al., 2014)	Scaling, orientation detection, thresholding	Spike-based	Supervised	Tempotron rule	91.3%
Two layer network (Brader et al., 2007)	Edge-detection	Spike-based	Supervised	STDP with calcium variable	96.5%
Multi-layer hierarchical network (Beyeler et al., 2013)	Orientation-detection	Spike-based	Supervised	STDP with calcium variable	91.6%
Two layer network (Querlioz et al., 2013)	None	Spike-based	Unsupervised	Rectangular STDP	93.5%
Two layer network (this paper)	None	Spike-based	Unsupervised	Exponential STDP	95.0%

Обучение как синхронизация

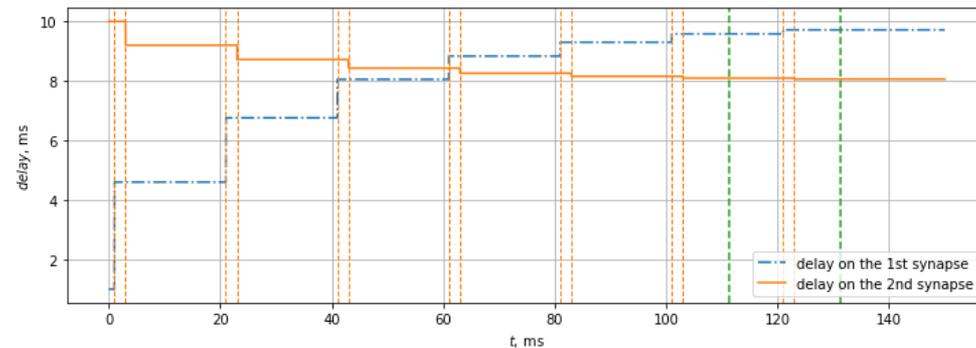
При обучении могут меняться не только **веса** связей, но и **задержки** распространения спайков

1. Nadafian A., Ganjtabesh M. Bio-plausible Unsupervised Delay Learning for Extracting Temporal Features in Spiking Neural Networks
 - Год публикации: 2020
 - Правило обучения: STDP-based delay learning rule
 - Задача: динамическая классификация
2. Hazan N. et al. Memory via Temporal Delays in weightless Spiking Neural Network
 - Год публикации: 2022
 - Правило обучения: weightless STDP-based delay learning rule
 - Задача: статическая классификация

Обучение как синхронизация



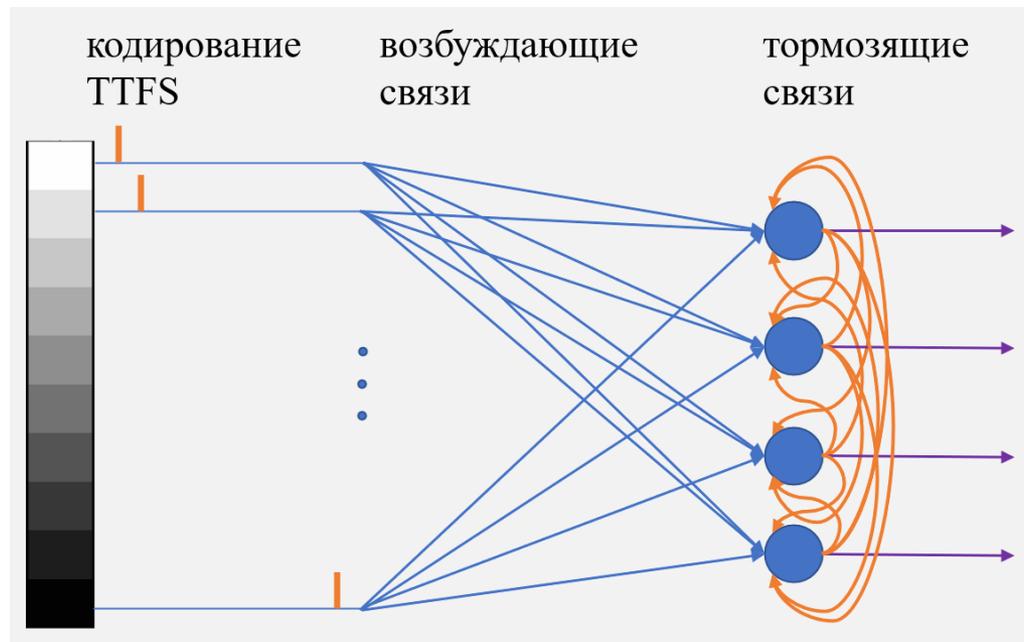
Изменение
мембранного
потенциала нейрона 3



Изменение задержек
на синапсах 1 и 2

Чаплинская Н.В. **Обучение спайковой нейронной сети на основе изменения временных задержек на синапсах.** Нейроинформатика – 2022, МФТИ, Москва

Обучение как синхронизация



Направленное изменение задержек с кодированием по времени первого спайка позволяет обучить сеть распознавать простые контрастные изображения

Чаплинская Н.В. **Обучение спайковой нейронной сети на основе изменения временных задержек на синапсах.** Нейроинформатика – 2022, МФТИ, Москва

Свойства спайковых нейросетей

1. **Импульсная передача информации** - нейрон оперирует потоком дискретных импульсов (спайков)
2. **Непрерывное время**
3. **Параллелизм и асинхронность** – фрагменты сети, не связанные друг с другом, работают независимо
4. **Локальное обучение** - меняются только связи между активными нейронами
5. **Разреженность потоков данных** – спайки (при временном кодировании) возникают сравнительно редко как во времени, так и в пространстве

План доклада

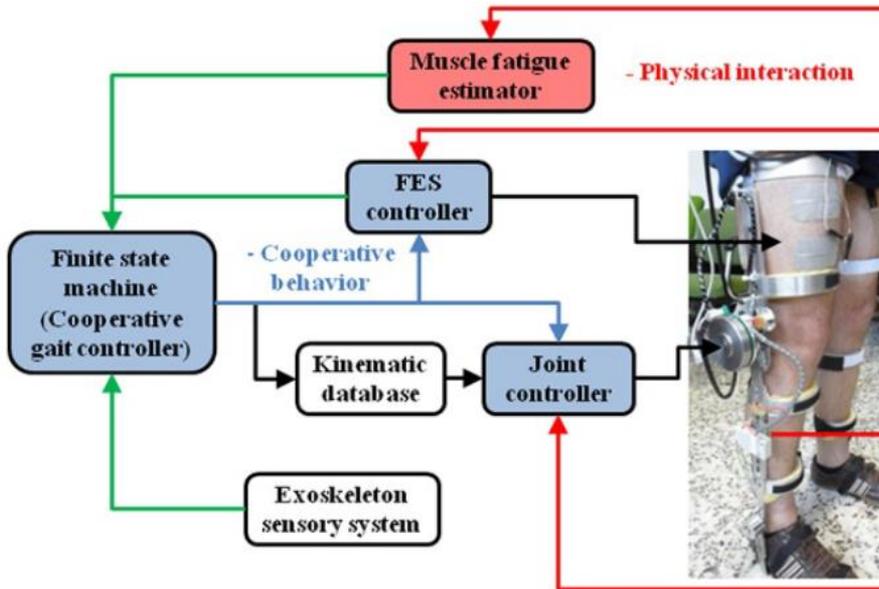
1. Спайковые нейросети
2. Кодирование информации и обучение
- 3. Нейроморфные системы управления**

Управление движениями

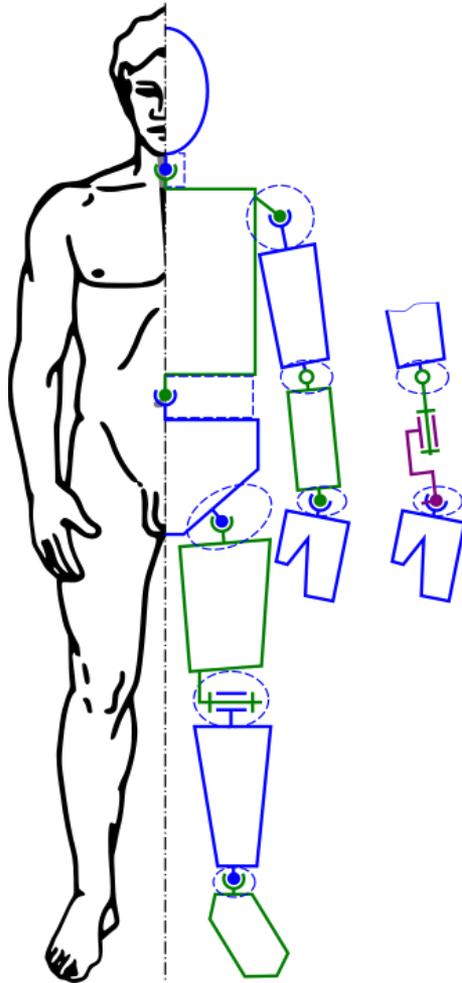


Приложения

1. Медицина: реабилитация, протезирование, диагностика
2. Робототехника
3. Имитация движений в играх, 3d моделировании и др.



Проблема степеней свободы

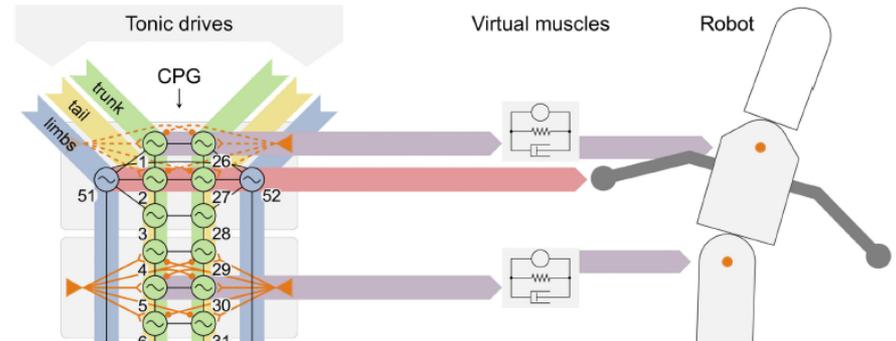
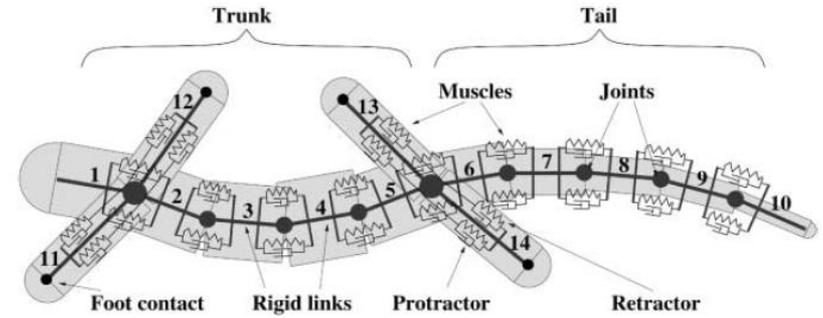


Человеческое тело имеет избыточные степени свободы на всех уровнях:

- 1. Анатомическом** – в мышцах и суставах
- 2. Кинематическом** – действия могут следовать по разным траекториям с разной скоростью, но достигнуть одной и той же цели
- 3. Нейрофизиологическом** – мышца может активироваться разными группами мотонейронов, которые могут активироваться разными сигналами от ЦНС

https://en.wikipedia.org/wiki/Degrees_of_freedom_problem

Нейроморфное управление



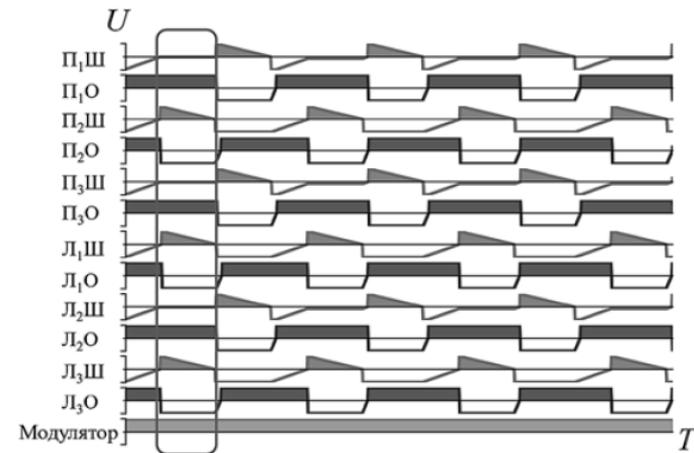
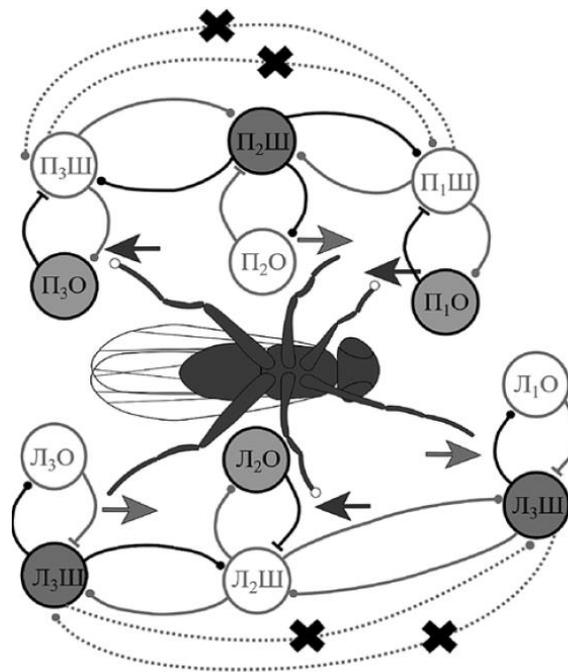
Ijspeert, A. J. (2001). A connectionist central pattern generator for the aquatic and terrestrial gaits of a simulated salamander. *Biological cybernetics*, 84(5), 331-348.

Knüsel, J., et.al.. (2020). Reproducing five motor behaviors in a salamander robot with virtual muscles and a distributed CPG controller regulated by drive signals and proprioceptive feedback. *Frontiers in neurobotics*, 14.

Пример. Переключение моторных ритмов

Задачи управления:

1. Генерировать правильную последовательность фаз движения
2. Переключать ритм в зависимости от команд верхнего уровня



Болдышев, Б. А., & Жиякова, Л. Ю. (2021). Нейромодуляция как инструмент управления нейронными ансамблями. *Проблемы управления*, 2(0), 76-84.

Управление локомоцией человека

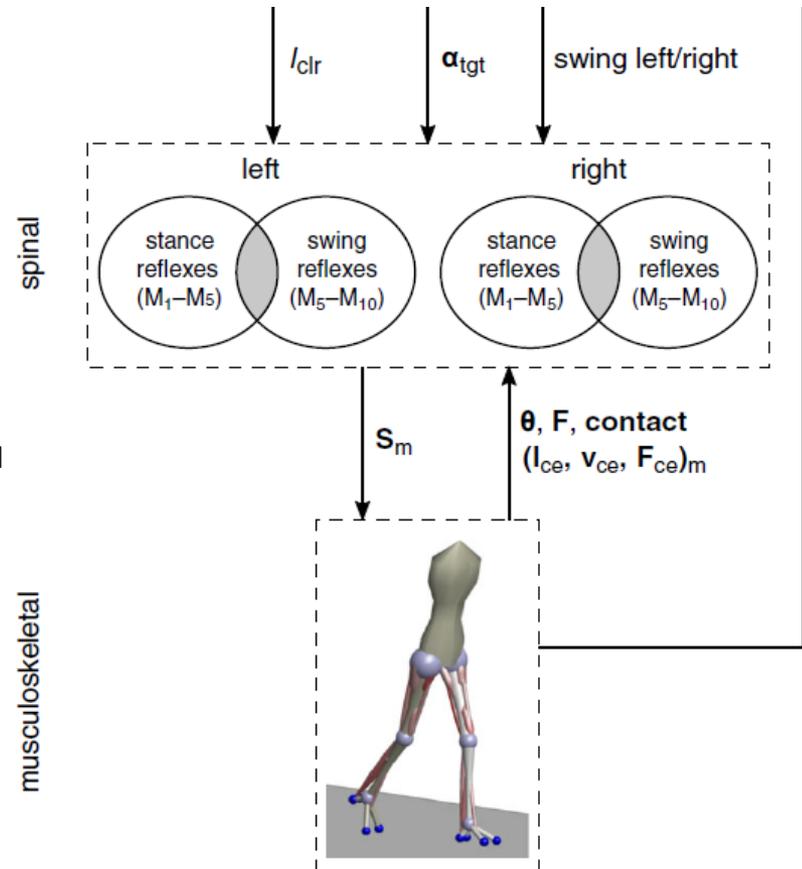
Супраспинальный уровень – выбор ноги и желаемого положения

Спинальный уровень – 10 «рефлексных модулей».

Каждый модуль – простой ПИД регулятор с несколькими логическими переключателями.

Отвечает за отдельную фазу движения, получая информацию о необходимых для него параметрах: сила в мышце, длина, скорость движения, отклонение от целевого значения и его производная

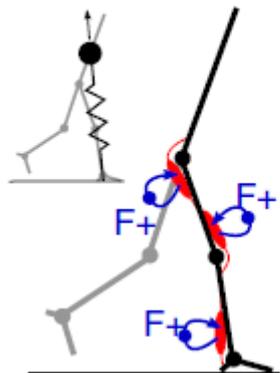
Примерно также устроены «умные» протезы



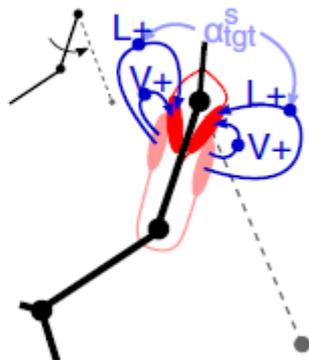
Song, S., & Geyer, H. (2015). A neural circuitry that emphasizes spinal feedback generates diverse behaviours of human locomotion. *The Journal of physiology*, 593(16), 3493-3511.

Управление локомоцией человека

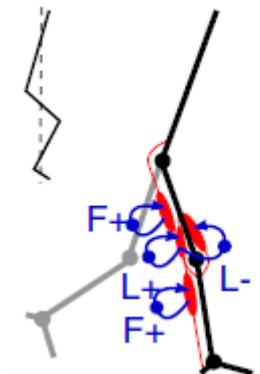
M₁ realize compliant leg



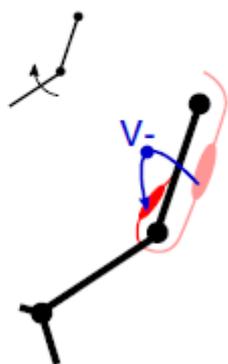
M₆ swing hip



M₂ prevent knee overextension



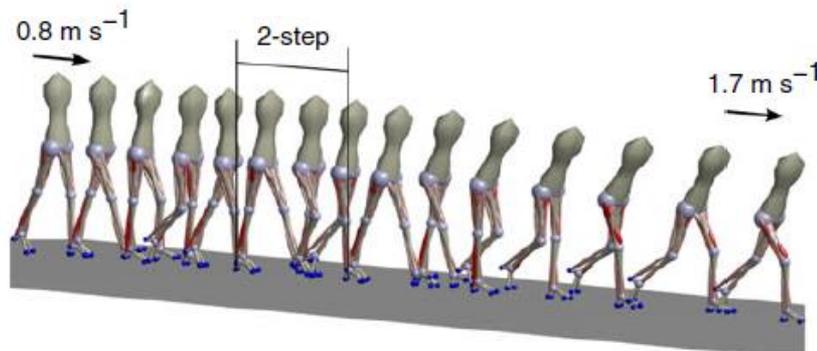
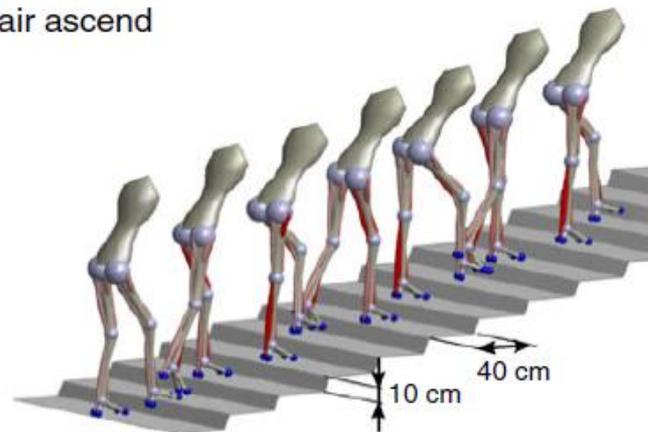
M₇ flex knee



Оптимизация параметров ~ 1 неделя на «современном ПК»

Разнообразие поведения:

stair ascend



Нейроморфные вычисления на школе по ИИ

Содержание курса:

- Введение в нейробиологию и спайковые нейронные сети
- Биофизические модели нейронов и синапсов. Идентификация моделей
- Кодирование информации в нервной системе
- Синаптическая пластичность и обучение
- Управление моторными ритмами
- Нейроморфные процессоры и приложения

Преподаватели

Практические занятия

Базенков Н.И., ИПУ РАН

Чаплинская Н.В., МГТУ им. Н.Э. Баумана,
ИПУ РАН



Материалы курса (за 2021 год)

<https://github.com/bazenzkov/neuro-raai>

Заключение

1. Моделирование биологических нейронов может дать новые возможности для решения задач ИИ
2. Для этого нужны новые принципы обучения
 1. Связь обучения и кодирования
 2. Пластичность и весов и задержек
3. Нейроморфные системы успешно решают сложные задачи управления движением

Спасибо за внимание!

Николай Базенков, лаб. 11
n.bazenzov@yandex.ru