

Алгоритм SCoBUL обучения без учителя импульсной нейронной сети и его применение для выделения информативных признаков из сигнала DVS камер

М. В. Киселев¹

Не так давно стал коммерчески доступен принципиально новый вид видеокамер, так называемые DVS камеры (dynamic vision sensor). Применение этих устройств способно радикально улучшить параметры скорости и энергоэкономичности процедур обработки видеосигнала за счет того, что они посылают на обработку не постоянно сканируемый растровый сигнал, а асинхронный поток спайков, индицирующих увеличение или уменьшение яркости отдельных пикселей. Принципиально новый характер посылаемого сигнала требует принципиально новых алгоритмов его обработки. Такой алгоритм, названный SCoBUL (spike correlation based unsupervised learning), описывается в данной работе. SCoBUL использует однослойную импульсную сеть с латеральным торможением для выделения первичных информативных признаков из потока спайков в режиме обучения без учителя. Главной чертой SCoBUL является обобщение законов синаптической пластичности STDP (spike timing dependent plasticity), специально оптимизированное для решения этой задачи.

Ключевые слова: DVS камера, импульсная нейронная сеть, нейронная сеть с латеральным торможением, обучение без учителя, синаптическая пластичность, STDP.

1. Введение

В последнее десятилетие импульсные нейронные сети (ИНС), класс нейросетевых моделей, основанный на принципах обработки информации, близких к тем, что используются в биологических нейронных ансамблях (главный из которых – импульсный характер обмена информацией), превращается из чисто академического объекта изучения в базу для построения практически применимых устройств с уникальными характеристиками по скорости работы и экономичности. Однако, для того, чтобы эти

¹ *Киселев Михаил Витальевич* — к.т.н., руководитель лаборатории нейроморфных вычислений, Чувашский государственный университет, e-mail: mkiselev1@yandex.ru

Kiselev Mikhail Vitalievich — candidate of technical sciences, Head of the Neuromorphic Computing Laboratory, Chuvash State University

преимущества реализовались, необходимо чтобы все этапы обработки информации, начиная с ее получения, подчинялись тем же принципам. Как ответ на этот запрос, появились, в том числе, видеокамеры, посылающие сигнал, представленный в виде потока импульсов (спайков), так что каждый отдельный спайк отмечает изменение в ту или иную сторону яркости единичного пикселя.

Первичным этапом обработки таких спайковых потоков видеоинформации, является выделение устойчивых структурных признаков, формирующих описание видеообразов, которое на следующих уровнях обработки будет использоваться для решения задач высокоуровневого анализа и распознавания. Эта задача является частным случаем обучения без учителя, так как не предполагается какой-либо предварительной разметки этого спайкового потока. Можно показать, что рассматриваемая задача может быть без потери общности представлена как задача выявления корреляций и антикорреляций между частотами спайков в разных последовательностях спайков в разных временных диапазонах (возможно, также с временным лагом).

Структуры ИНС, используемые для задач обучения без учителя достаточно единообразны – это, как правило, однослойные сети с возбуждающими пластичными связями с входными узлами и сильными непластичными тормозными связями между нейронами. Предложенный в данной работе алгоритм обучения без учителя SCoBUL (spike correlation based unsupervised learning) также использует эту архитектуру. Имея в виду максимально эффективную реализацию ИНС (в том числе, на современных специализированных нейропроцессорах, таких как TrueNorth, Loihi или Алтай – см. обзор в [1]), использована, вероятно, самая простая функциональная модель импульсного нейрона, LIF (leaky integrate-and-fire neuron – пороговый интегратор с утечкой). Основным новшеством данной работы и чертой алгоритма SCoBUL является закон пластичности, оптимизированный для использования в рассматриваемой задаче.

2. Оптимизированная модель пластичности SCoBUL

Обучение ИНС принципиально отличается от обучения традиционных нейронных сетей с силу невозможности непосредственного применения методов градиентного спуска к этим дискретным по своей природе системам. В силу этого, обучение ИНС строится на законах синаптической пластичности, подчиняющихся принципу локальности, что означает, что изменения синаптического веса могут зависеть только от характеристик

активности пре- и пост-синаптического нейрона. Классическим примером такого закона пластичности является модель STDP (spike timing dependent plasticity) [2]. Эта модель в определенной степени соответствует биологической реальности, однако многие ее свойства делают ее далеко не оптимальным выбором для решения поставленной задачи. В числе этих негативных свойств – ограничения по распознаванию «размазанных» во времени корреляций из-за раннего срабатывания распознающего нейрона и ослабления синапсов, принявших «запоздавшие» спайки, нерешенность проблемы катастрофического забывания, необратимость полного подавления нейрона и другие. Присутствие в STDP экспоненциальной зависимости от времени делает не очень эффективной ее реализацию на цифровых нейрочипах.

В результате проведенного анализа задачи первичной обработки DVS сигнала с точки зрения ее формализации как задачи выделения статистически значимых корреляций частот спайков, а также на основе предложенной в моих более ранних работах модели пластичности, решающей проблему катастрофического забывания, [3] и требования эффективной реализации на цифровых нейрочипах, в данной работе предлагается новая модель пластичности, являющаяся модификацией классического STDP. Наиболее важные черты этой модели (также названной SCoBUL) следующие:

- Аддитивные законы пластичности применяются не к весу синапса w , а к монотонно с ним связанной по формуле

$$w = w_{min} + \frac{(w_{max} - w_{min}) \max(W, 0)}{w_{max} - w_{min} + \max(W, 0)}$$

величине синаптического ресурса W . Очевидно, что, если W пробегает от $-\infty$ до $+\infty$, w изменяется от w_{min} до w_{max} . Эта поправка дает эффект стабилизации, противодействия катастрофическому забыванию – если синаптический вес находится в районе насыщения (т.е., когда W или отрицательный, или очень большой положительный), то шумовые данные или данные, содержащие другие паттерны, не похожие на прежде распознаваемые, не сразу разрушают обученное состояние сети, а лишь после количества предъявлений, сравнимого с тем, которое было использовано для обучения сети.

- Синапсы усиливаются, если получают спайки в пределах небольшого временного окна около постсинаптического спайка, не важно – до или после него. Это дает возможность распознать весь длящийся во времени паттерн, а не только его начальную часть. Спайки, пришедшие вне этого временного окна, всегда ослабляют синапс.

Величины увеличения и уменьшения синаптического ресурса всегда постоянны, что значительно упрощает аппаратную реализацию модели.

- Суммарный синаптический ресурс нейрона остается постоянным. Т.е. если одни синапсы усиливаются, то другие ослабляются и наоборот. Это приводит к более выраженной конкуренции между синапсами и решает проблему непластичности молчащих нейронов.
- Синапсы с большим весом, но редко принимающие участие в генерации постсинаптического спайка, ослабляются. Это дает возможность избежать ситуации, когда один и тот же нейрон распознает несколько некоррелирующих паттернов.

Кроме описанного закона пластичности алгоритм SCoBUL использует динамическую структуру сети – полностью подавленные нейроны разрушаются и пересоздаются заново, получая шанс распознать какие-то еще ранее нераспознанные паттерны в данных.

3. Экспериментальное подтверждение

Для экспериментального подтверждения преимуществ модели пластичности SCoBUL перед STDP были проведены эксперименты на созданном мной программном эмуляторе DVS камеры. Например, проводились оценки точности предсказания нейронами сети положения центра светового пятна, движущегося в разных направлениях и с разными скоростями в поле зрения эмулируемой DVS камеры, в 4-мерном фазовом пространстве с метрикой, уравнивающей стандартные отклонения положения пятна в пространственных и скоростных координатах. Для оптимизации гиперпараметров сети в обоих случаях использовался генетический алгоритм, при одинаковых или эквивалентных диапазонах вариации этих параметров. В проведенных экспериментах точность позиционирования пятна сетью с пластичностью SCoBUL оказывалась существенно (на 30% - 45%) выше, чем сетью, использующей классический STDP. В настоящее время проводится исследование по более систематической оценке качества SCoBUL и ограничений его применимости.

Список литературы

- [1] Ларионов Д., Киселев М., Иванов Д., “Нейроморфные системы ИИ”, *Альманах «Искусственный интеллект»*, 2021, № 9, 49–61.

- [2] Bi G.Q., Poo M.M., “Synaptic modifications in cultured hippocampal neurons: dependence on spike timing, synaptic strength, and postsynaptic cell type”, *Journal of Neuroscience*, **18**:24 (1998), 10464–10472.
- [3] Kiselev M., “Rate Coding vs. Temporal Coding – Is Optimum Between?”, *Proceedings of IJCNN-2016*, 2016, 1355–1359.

Spiking neural network unsupervised learning algorithm SCoBUL and its application to extracting informative features from DVS camera signal
Kiselev M.V.

A principally new type of video cameras, the so-called DVS (dynamic vision sensors), became commercially available recently. They are capable of enhancing dramatically speed and energy consumption parameters of video signal processing procedures because they send asynchronous stream of spikes indicating brightness change of individual pixels instead of scanned raster data of the whole camera view field. However, this new kind of output signal requires novel algorithms for its processing. Such an algorithm called SCoBUL (spike correlation based unsupervised learning) is described in the present work. SCoBUL uses a one-layer spiking neural network with lateral inhibition for extracting informative features from spike trains in unsupervised learning regime. SCoBUL’s most important feature is a generalization of STDP (spike timing dependent plasticity) rule optimized especially for this task.

Keywords: DVS, spiking neural network, network with lateral inhibition, unsupervised learning, synaptic plasticity, STDP.

References

- [1] Larionov, D., Kiselev, M., Ivanov D., “Neuromorphic systems of AI”, *Almanac «Artificial Intelligence»*, 2021, №9, 49–61 (In Russian).
- [2] Bi G.Q., Poo M.M., “Synaptic modifications in cultured hippocampal neurons: dependence on spike timing, synaptic strength, and postsynaptic cell type”, *Journal of Neuroscience*, **18**:24 (1998), 10464–10472.
- [3] Kiselev M., “Rate Coding vs. Temporal Coding – Is Optimum Between?”, *Proceedings of IJCNN-2016*, 2016, 1355–1359.