

ВЛИЯНИЕ КОРРЕЛЯЦИИ СПАЙКОВЫХ ПОСЛЕДОВАТЕЛЬНОСТЕЙ НА ОБУЧЕНИЕ НЕЙРОННОЙ СЕТИ ПОД ДЕЙСТВИЕМ SPIKE-TIMING-DEPENDENT PLASTICITY

© 2020 г. А. Г. Сбоев^{1,2,*}, Р. Б. Рыбка^{2,**}, А. В. Серенко^{2,***}

¹ Национальный исследовательский ядерный университет “МИФИ”, Москва, 115409, Россия

² Национальный исследовательский центр “Курчатовский институт”, Москва, 123182, Россия

*e-mail: sag111@mail.ru

**e-mail: rybkarb@gmail.com

***e-mail: serenko@phystech.edu

Поступила в редакцию 19.12.2019 г.

После доработки 19.12.2019 г.

Принята к публикации 21.01.2020 г.

Рассматривается возможность обучения двуслойной спайковой нейронной сети на основе STDP с использованием эффекта стабилизации выходной частоты. Численными симуляциями показано, что при достаточно большой корреляции между входными спайковыми последовательностями нейрона стабилизация его средней выходной частоты под действием STDP не происходит из-за недостаточной конкуренции входных синапсов. Для двуслойной сети показано, что спайки, поступающие на вход нейронов второго слоя, могут коррелировать из-за частичного совпадения установившихся под действием STDP весов первого слоя. Чтобы добиться стабилизации выходной частоты второго слоя, предложен способ уменьшить корреляцию выходных спайков нейронов первого слоя путем увеличения количества их входов, что уменьшит близость весов, установившихся под действием STDP у различных нейронов первого слоя. Возможность применения двуслойной сети с размножением входов к решению задачи классификации продемонстрирована на тестовой задаче ирисов Фишера, и точность классификации составила 93% по метрике F1, что находится на одном уровне с существующими в литературе подходами к обучению спайковых сетей при кодировании входных данных средними частотами входящих спайковых последовательностей.

Ключевые слова: спайковые нейронные сети, синаптическая пластичность, машинное обучение

DOI: 10.1134/S2304487X20010083

1. ВВЕДЕНИЕ

Модели биологических (спайковых) нейронных сетей приобретают в последнее время все большую актуальность для применения в задачах машинного обучения благодаря прогрессу в возможности их аппаратной реализации на нейроморфных вычислительных устройствах с чрезвычайно низким энергопотреблением [1–4]. Применение спайковых сетей к решению задачи классификации включает в себя три компонента: способ кодирования входных данных во входящие спайковые последовательности, механизм обучения сети, и способ декодирования выходной активности нейронов в результат классификации.

Один из общепринятых [5] способов кодирования данных — частотный, в котором компоненты входного вектора отображаются в частоты пуассоновских спайковых последовательностей, подаваемых на входящие синапсы сети. Одним из

возможных подходов к созданию и обучению спайковой сети, решающей задачу классификации с частотным кодированием данных, является перенос синаптических весов с предварительно обученной формальной нейронной сети той же топологии. Однако более актуальны алгоритмы обучения спайковой сети на основе локальных правил синаптической пластичности, таких, как Spike-Timing-Dependent Plasticity (STDP) [6], ввиду возможности реализации последней на мемристорных устройствах. Существует несколько работ, посвященных решению задачи классификации спайковой сетью на основе STDP с частотным кодированием входных данных. Сеть [7] из одного слоя возбуждающих нейронов с STDP-пластичностью входных синапсов, в которой каждый возбуждающий нейрон тормозил своей активностью все остальные (посредством слоя тормозящих нейронов с фиксированными связями), обучалась распознаванию рукописных цифр MNIST.

В другой работе [8] набор из трех не связанных между собой нейронов обучался классифицировать ирисы Фишера, при этом обучение было основано на эффекте стабилизации под действием STDP средней выходной частоты нейрона [9–11].

Но обе приведенные выше сети с частотным кодированием данных были однослойными. В многослойной же сети прямого распространения при частотном кодировании существует принципиальное различие между первым слоем и последующими: на вход первого слоя поступают сгенерированные независимые пуассоновские последовательности спайков, а последующие слои получают спайки, испущенные нейронами предыдущих слоев, и эти спайки могут коррелировать между собой в зависимости от степени совпадения синаптических весов нейронов, их испускающих. Такая корреляция может существенно влиять [12] на веса, устанавливающиеся под действием STDP. В частности, может не выполняться эффект стабилизации выходной частоты. Поэтому цель данной статьи – изучить влияние взаимной корреляции последовательностей спайков на обучение двуслойной нейронной сети под действием STDP.

В разделе 3 численными экспериментами на примере одного нейрона Integrate-and-Fire с искусственно сгенерированными входными спайковыми последовательностями показано, что при наличии корреляции между входными последовательностями не выполняется эффект стабилизации под действием STDP выходной частоты нейрона. В разделе 4 представлено, что когда нейрон находится во втором слое двуслойной нейронной сети, входы этого нейрона коррелируют между собой достаточно сильно, чтобы стабилизация выходной частоты не происходила. Предложен способ подавления корреляции выходов нейронов первого слоя путем увеличения количества входящих синапсов этих нейронов. В разделе 5 с применением данного способа продемонстрирована возможность обучения двуслойной нейронной сети решению задачи классификации ирисов Фишера.

2. МЕТОДЫ

2.1. Модель синаптической пластичности

Рассматривается разновидность Spike-Timing-Dependent-Plasticity, для которой был ранее показан [11] эффект стабилизации выходной частоты, – аддитивная STDP с ограниченной симметричной схемой учета пар спайков.

В этой модели изменение синаптического веса w зависит только от разности момента пресинаптического спайка $t_{\text{пре}}$ и момента постсинаптического спайка $t_{\text{пост}}$:

$$\Delta w = \begin{cases} -\alpha \lambda \exp\left(-\frac{t_{\text{пре}} - t_{\text{пост}}}{\tau^-}\right) & \text{при } t_{\text{пре}} - t_{\text{пост}} > 0; \\ \lambda \exp\left(-\frac{t_{\text{пост}} - t_{\text{пре}}}{\tau^+}\right) & \text{при } t_{\text{пре}} - t_{\text{пост}} < 0. \end{cases} \quad (1)$$

Здесь константа λ определяет максимальную величину отдельного изменения веса; ее целесообразно брать настолько малой, насколько позволяют вычислительные ресурсы; у синапсов нейрона в разделе 3, а также в первом слое двуслойной сети в разделах 4 и 5 она была взята равной 0.01. Остальные константы были взяты как в литературе [13]: $\alpha = 1.035$, $\tau^+ = \tau^- = 20$ мс. Для второго слоя сети константы подбирались отдельно.

В ограниченной симметричной схеме учета пар спайков произошедший постсинаптический спайк приводит к увеличению веса по правилу 1, при этом в качестве $t_{\text{пре}}$ учитывается ближайший предшествовавший пресинаптический спайк, но только в том случае, если между ним и текущим пост-спайком не было других пост-спайков. Аналогично, приход на синапс пресинаптического спайка приводит к уменьшению веса, при этом в качестве $t_{\text{пост}}$ учитывается ближайший предшествовавший постсинаптический спайк, но только в том случае, если между ним и текущим пре-спайком не было других пре-спайков. Таким образом, каждый постсинаптический и пресинаптический спайк может не учитываться не более чем в одном акте увеличения веса и одном акте уменьшения веса.

Чтобы не позволить весу превысить 1 или упасть ниже 0, при каждом изменении веса после вычисления Δw применяется дополнительное условие: если $w + \Delta w > w_{\text{max}}$, то $\Delta w = w_{\text{max}} - w$; если $w + \Delta w < 0$, то $\Delta w = -w$.

2.2. Модель нейрона – пороговый сумматор без утечки

В разделе 3 в качестве модели нейрона использовался пороговый интегратор без утечки (Integrate-and-Fire), в котором при приходе входного спайка на i -й синапс с весом w_i мембранный потенциал (безразмерный) скачком повышается на w :

$$\frac{dV}{dt} = \sum_i \sum_{t_{\text{sp}}^i} w_i(t) \delta(t - t_{\text{sp}}^i),$$

где t_{sp}^i – моменты прихода входных спайков на i -й синапс. При превышении потенциалом порога $V_{\text{th}} = 100$ нейрон испускает спайк, и потенциал скачком сбрасывается до 0. Рефрактерность отсутствует.

Данная модель нейрона была выбрана за свою простоту, при этом эффект стабилизации выходной частоты, как было показано ранее [14], вы-

полняется для нее так же, как и для интегратора с утечкой (Leaky Integrate-and-Fire).

Нейрон имел 40 входящих синапсов (количество синапсов не влияет на качественный результат экспериментов и ограничено лишь вычислительными ресурсами), на 20 поступали независимые пуассоновские последовательности спайков, а на другие 20 – набор последовательностей, все из которых попарно коррелировали между собой с заданным коэффициентом корреляции Пирсона c . Средние частоты всех входных последовательностей, и коррелирующих, и некоррелирующих, были одинаковы в ходе симуляции, но различались в различных экспериментах. В начале симуляции все веса устанавливались равными 0.1: это значение было выбрано, поскольку его достаточно для того, чтобы нейрон был способен испускать спайки при всех используемых входных частотах; при этом начальное значение веса, как было показано ранее, не оказывает существенно влияния на распределение весов, устанавливающееся под действием STDP.

2.3. Модель нейрона – сумматор с утечкой

В разделах 4 и 5 используется модель нейрона, часто применяемая в экспериментах по обучению, – Leaky Integrate-and-Fire. В ней мембранный потенциал подчиняется уравнению

$$\frac{dV}{dt} = \frac{-(V(t) - V_{\text{rest}})}{\tau_m} + \frac{I_{\text{syn}}(t)}{C_m},$$

где потенциал покоя нейрона V_{rest} взят равным – 70 мВ, константа времени утечки $\tau_m = 10$ мс, емкость мембраны C_m выбиралась различной в разных экспериментах в зависимости от количества входящих синапсов. При превышении потенциалом порога $V_{\text{th}} = -54$ мВ нейрон испускает спайк, и потенциал скачком сбрасывается до V_{rest} .

Входящий постсинаптический ток имел экспоненциальную форму

$$I_{\text{syn}} = \sum_i \sum_{t_{\text{sp}}^i} w_i(t_{\text{sp}}^i) \frac{q_{\text{syn}}}{\tau_{\text{syn}}} e^{-\frac{t-t_{\text{sp}}^i}{\tau_{\text{syn}}}} \Theta(t - t_{\text{sp}}^i),$$

где $\tau_{\text{syn}} = 5$ мс, $q_{\text{syn}} = 5$ фКл, Θ – функция Хевисайда.

2.4. Метод генерации коррелирующих последовательностей спайков

В разделе 3 для генерации последовательностей спайков, коррелирующих между собой с заданным коэффициентом c и при этом имеющих одинаковую среднюю частоту r , использовался алгоритм, предложенный в литературе [12]. Моменты спайков измеряются с точностью до временного шага симуляции $\delta t = 0.1$ мс. Вначале ге-

нерируется эталонная пуассоновская последовательность S_0 средней частоты r путем прохода по дискретным временным шагам и генерации спайка с вероятностью $P(S_0 = 1) = r\delta t$ на каждом временном шаге (1 обозначает наличие спайка, 0 – отсутствие спайка). Затем каждая из 20 коррелирующих последовательностей S_i создается из эталонной последовательности по следующему правилу: временной шаг, содержащий спайк в эталонной последовательности, с вероятностью $P(S_i = 1|S_0 = 0) = \Theta$ будет содержать спайк и в производной последовательности; с вероятностью $P(S_i = 0|S_0 = 0) = 1 - \Theta$ данный временной шаг в производной последовательности будет пустым. Если же на данном временном шаге эталонная последовательность не содержит спайка, то в производной последовательности на этом шаге спайк может возникнуть с вероятностью $P(S_i = 1|S_0 = 0) = \varphi$.

φ выбирается так, чтобы частота производных последовательностей равнялась частоте эталонной последовательности r :

$$\varphi = r\delta t(1 - \sqrt{c}).$$

Действительно, тогда $M[S_i] = P(S_i = 1|S_0 = 1) + P(S_i = 1|S_0 = 0) = r\delta t$.

Θ выбирается так, чтобы коэффициент корреляции Пирсона между двумя производными последовательностями равнялся c :

$$\Theta = r\delta t + (1 - r\delta t)\sqrt{c}.$$

Действительно, тогда частота совместной встречаемости спайков в любых двух производных последовательностях $M[S_i S_j] = P(S_i = 1, S_j = 1) = P(S_0 = 1)P(S_i = 1|S_0 = 1)P(S_j = 1|S_0 = 1) + P(S_0 = 0)P(S_i = 1|S_0 = 0)P(S_j = 1|S_0 = 0) = r\delta t\Theta^2 + (1 - r\delta t)\varphi^2$. Учитывая, что дисперсия $D[S_i] = r\delta t(1 - r\delta t)$, коэффициент корреляции между S_i и S_j

$$\frac{M[S_i S_j] - M[S_i]M[S_j]}{\sqrt{D[S_i]D[S_j]}} = c.$$

3. ВЛИЯНИЕ ВЗАИМНОЙ КОРРЕЛЯЦИИ ВХОДНЫХ СПАЙКОВЫХ ПОСЛЕДОВАТЕЛЬНОСТЕЙ НА УСТАНОВИВШЕЕСЯ РАСПРЕДЕЛЕНИЕ ВЕСОВ НЕЙРОНА

3.1. Методика эксперимента

Чтобы изучить, как корреляция входных спайковых последовательностей влияет на конкуренцию входов между собой за вклад в выходную спайковую активность нейрона, моделировался нейрон Integrate-and-Fire (описанный в разделе 2.2), на половину входов которого поступали незави-

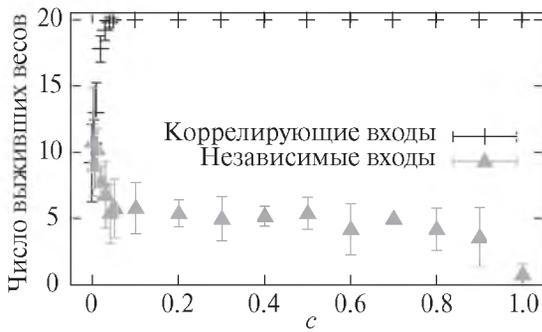


Рис. 1. Количество весов, установившихся вблизи 1, в группе коррелирующих входов и в группе независимых входов, в зависимости от коэффициента корреляции c группы коррелирующих входов. Средняя частота всех входных последовательностей спайков составляла 20 Гц. Погрешность приведена по 5 запускам с различными сгенерированными входными спайковыми последовательностями.

симые последовательности спайков, а на другую — коррелирующие. При этом исследовалось влияние величины корреляции входных последовательностей на распределения установившихся под действием STDP синаптических весов в обеих половинах входов — коррелирующей и независимой. Далее проверялось, выполняется ли эффект стабилизации выходной частоты нейрона при наличии корреляции во входах. Для этого при различных входных частотах выходная частота нейрона при установившихся под действием STDP весах, сравнивалась с установившейся выходной частотой, полученной при отсутствии корреляции во входах.

3.2. Результаты

Под действием рассматриваемой аддитивной разновидности STDP устанавливается бимодальное распределение синаптических весов: после длительной симуляции каждый вес устанавливается либо вблизи своего максимального значения, 1, либо вблизи минимального значения, 0. Дальнейшие флуктуации весов, вызванные случайным характером отдельных актов изменения, происходят в пределах $[0; 0.2]$ и $[0.9; 1]$. При этом при уменьшении константы λ , управляющей максимальной величиной отдельного изменения веса, эти интервалы уменьшаются, поэтому ими можно пренебречь и описывать стационарное распределение весов количеством весов, установившихся вблизи 1 и вблизи 0 (далее для краткости — выживших и отмерших весов).

На рис. 1 приведена зависимость количества выживших весов в группах коррелирующих и независимых входов от корреляции c входов в коррелирующей группе. При $c < 0.01$ в коррелирующей и независимой группах выживает одинако-

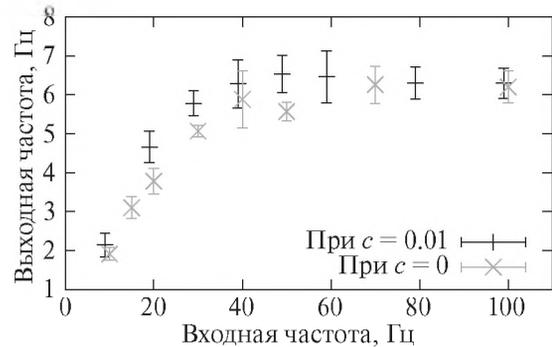
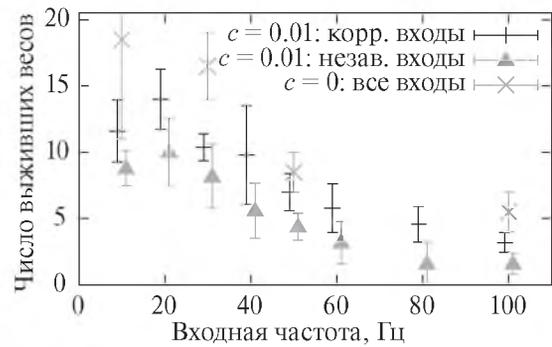


Рис. 2. Вверху: количество весов, установившихся вблизи 1, в группе коррелирующих входов и в группе независимых входов, в зависимости от входной частоты, при корреляции $c = 0.01$ между входными последовательностями коррелирующей группы входов; а также, для сравнения, количество выживших весов при $c = 0$. Внизу: выходная частота при весах, установившихся под действием STDP; в том числе, для сравнения, при $c = 0$, то есть в случае, когда на все входы нейрона поступали независимые последовательности.

вое количество весов. В диапазоне от 0.01 до 0.05 с ростом c количество выживших весов в коррелирующей группе увеличивается, а в независимой группе — уменьшается, что указывает на то, что под действием STDP происходит конкурентная борьба входов между собой, в которой коррелирующие входы получают преимущество. $c > 0.05$ оказывается достаточно большой для того, чтобы при выбранных параметрах нейрона и STDP все веса в коррелирующей группе входов выживали.

На рис. 2 при $c = 0.01$ (что, согласно приведенным выше результатам, соответствует относительно небольшой корреляции) менялась входная частота. В коррелирующей группе выживает немного больше входов, чем в независимой, но с ростом входной частоты количество выживших входов уменьшается в обеих группах. Рис. 2 (внизу) показывает, что выходная частота при установившихся таким образом весах одинакова при любой входной частоте от 20 Гц до 100 Гц, демонстрируя таким образом эффект стабилизации вы-

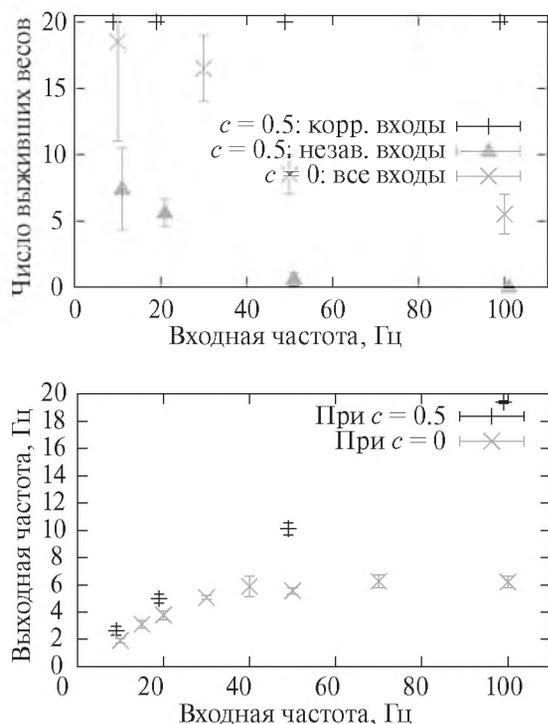


Рис. 3. Зависимость выживших весов (вверху) и установившейся выходной частоты (внизу) от входной частоты при корреляции $c = 0.5$ между входными последовательностями коррелирующей группы входов и, для сравнения, при $c = 0$. Погрешности показывают разброс по 5 запускам.

ходной частоты. Для сравнения на том же графике зависимости числа выживших весов (из всех 40) и установившейся выходной частоты от входной приведена для $c = 0$, и видно, что при $c = 0.01$ стабилизация выходной частоты происходит в том же диапазоне входных частот, что и при $c = 0$.

На рис. 3 та же зависимость, что на рис. 2, приведена для $c = 0.5$ — значения, которое, согласно результатам рис. 1, соответствует достаточно большой корреляции. Теперь при входной частоте до 500 Гц в коррелирующей группе входов выживают все веса. В независимой же группе входов, как и на рис. 2, с ростом входной частоты уменьшается количество выживших входов, до тех пор, пока не отмирают все из них. Что касается установившейся выходной частоты, то в диапазоне от 50 Гц до 500 Гц, поскольку распределение установившихся весов неизменно, выходная частота линейно растет с ростом входной.

Таким образом, при достаточно большой корреляции входных спайковых последовательностей стабилизация выходной частоты не происходит. В следующем разделе изучается возможность стабилизации выходной частоты нейрона второго слоя двуслойной сети.

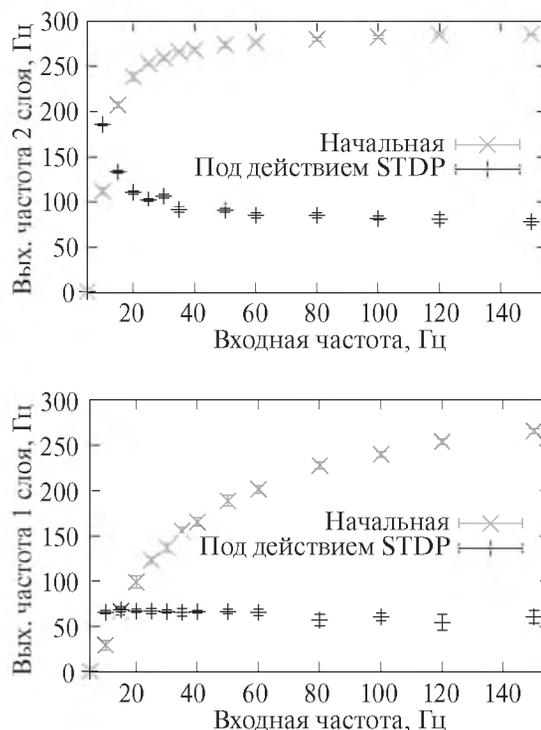


Рис. 4. Выходная частота нейрона второго (вверху) и первого (внизу) слоя сети при случайных начальных весах и при весах, установившихся под действием STDP. Погрешность показывает разброс между нейронами слоя.

4. ВЛИЯНИЕ КОРРЕЛЯЦИИ АКТИВНОСТИ НЕЙРОНОВ ПЕРВОГО СЛОЯ СЕТИ НА УСТАНОВИВШУЮСЯ ЧАСТОТУ ВТОРОГО СЛОЯ

4.1. Методика эксперимента

Чтобы выяснить возможность стабилизации выходной частоты нейрона, на вход которого поступают выходные спайки нейронов предыдущего слоя сети, моделируется двуслойная сеть со 100 нейронами в первом слое и 10 во втором. На вход сети поступают 100 пуассоновских последовательностей одинаковой средней частоты, которые подаются на 100 входящих синапсов каждого из нейронов первого слоя. Начальные веса всех синапсов выбираются из равномерного распределения от 0 до 1.

Константа STDP λ для второго слоя выбиралась достаточно малой, чтобы в процессе эволюции весов второй слой не перестал спайковать в случае спонтанного одновременного уменьшения весов первого и второго слоев.

4.2. Результаты

На рис. 4 (вверху) приведена выходная частота нейрона второго слоя при случайных начальных весах и при весах, установившихся под действием STDP. При начальных весах выходная частота

растет с ростом входной, пока не достигает максимально возможной для нейрона с рефрактерностью τ_{ref} частоты $\frac{1}{\tau_{\text{ref}}} \approx 300$ Гц. Однако частота при весах, установившихся под действием STDP, тем меньше, чем больше входная частота. Для сравнения на рис. 4 (внизу) приведена также установившаяся выходная частота нейрона первого слоя: в первом слое, получающем некоррелирующие входные последовательности, происходит стабилизация выходной частоты.

Причина обратной зависимости установившейся выходной частоты второго слоя от входной частоты первого слоя состоит в том, что с ростом входной частоты частота выходных спайков первого слоя остается неизменной, но корреляция их уменьшается. Действительно, чем больше входная частота, тем меньше выживает входов первого слоя (обеспечивая постоянство выходной частоты). Следовательно, тем меньше входов первого слоя случайно окажутся выжившими одновременно у нескольких нейронов, и тем меньше вероятность, что один и тот же входной спайк приведет к выходному спайку одновременно нескольких нейронов. Но чем меньше корреляция выходных спайков первого слоя, тем меньше весов выживут во втором слое, и, соответственно, тем меньше его установившаяся выходная частота.

Из данного результата следует, что стабилизация выходной частоты второго слоя возможна при низкой корреляции выходных спайков первого слоя. Уменьшения корреляции выходов первого слоя можно добиться следующими способами.

1. Высокая входная частота первого слоя (на рис. 4 – больше 50 Гц).
2. Большое число входов нейронов первого слоя. Это должно понизить в первом слое количество совпадающих выживших входов, поскольку вследствие эффекта стабилизации выходной частоты количество выживших входов зависит только от входной частоты и констант STDP и нейрона, но не зависит от общего числа входов.
3. Тормозящие связи между нейронами первого слоя.

В следующем разделе на примере задачи классификации ирисов Фишера применяются способы 1 и 2, но для сравнения также реализуется сеть из литературы с тормозящими входами.

5. ВОЗМОЖНОСТЬ ОБУЧЕНИЯ ДВУСЛОЙНОЙ СЕТИ ПРИ ПОДАВЛЕНИИ КОРРЕЛЯЦИИ В ПЕРВОМ СЛОЕ ПУТЕМ РАЗМНОЖЕНИЯ ВХОДОВ

5.1. Тестовый набор данных

В качестве тестовой задачи классификации используется задача ирисов Фишера. Этот набор

данных состоит из 150 цветков, принадлежащих к трем классам, которые соответствуют трем видам – *Iris Setosa Canadensis*, *Iris Virginica* и *Iris Versicolour*, по 50 цветков в каждом. Цветок описывается вектором из 4 компонентов: длина и ширина лепестка и чашелистика (в сантиметрах). При этом первые два класса можно отличить друг от друга линейным разделением в пространстве векторов, а третий класс не отделим линейно от первых двух.

Перед кодированием входных векторов в частоты входных спайковых последовательностей вектора нормировались так, чтобы их евклидова норма равнялась 1.

5.2. Методика эксперимента

Для демонстрации возможности обучения двуслойной сети используется задача классификации ирисов Фишера. При обучении и тестировании моделируются три сети, по одной на каждый класс. Сеть состоит из 60 нейронов Leaky Integrate-and-Fire (описанных в разделе 2.3) в первом слое и одного нейрона во втором слое. Каждый нейрон первого слоя получает на вход комбинацию 2 компонентов входного вектора. Всего из 4 компонентов возможно 6 комбинаций по 2 компонента, и каждая комбинация подается на 10 нейронов. При этом каждому компоненту входного вектора ставится в соответствие 50 входящих синапсов нейрона, на которые поступают независимые пуассоновские последовательности спайков с частотой, пропорциональной значению x нормированного компонента входного вектора: $xv_h + v_l$, где $v_h = 300$ Гц и $v_l = 3$ Гц. Один входной пример подается в течение 2 с.

STDP-пластичностью обладают входящие синапсы обоих слоев; в первом слое параметры STDP такие же, как в разделах 3 и 4: $\lambda = 0.01$, $\alpha = 1.035$, $\tau^+ = \tau^- = 20$ мс, а во втором слое подбирались отдаленно: $\lambda = 7 \times 10^{-3}$ (взята меньше, чем в первом слое, согласно соображениям, приведенным в разделе 4.1), $\alpha = 1.18$, $\tau^+ = 90$ мс, $\tau^- = 8$ мс. Емкость мембраны нейрона C_m в первом слое была выбрана равной 0.55 пФ, во втором слое – 4.0 пФ. На этапе обучения каждая сеть получает входные векторы, кодирующие примеры обучающей выборки своего класса. На этапе тестирования STDP выключается (путем выставления $\lambda = 0$ в обоих слоях), на каждую сеть подаются примеры обучающей и тестировочной выборки всех классов, и записываются выходные частоты нейронов второго слоя всех сетей в ответ на входные примеры.

Декодирование выходных частот сетей в результирующие метки классов осуществляется путем обучения традиционного классификатора Decision Tree или Gradient Boosting из библиотеки sklearn на выходных частотах обученной спайко-

вой сети. При этом классификатор обучается на выходных частотах спайковой сети, полученных в ответ на примеры тренировочной выборки, а затем по выходным частотам сети в ответ на примеры тестовой выборки предсказывает их классы. Поскольку для обучения спайковой сети на основе эффекта стабилизации выходной частоты пока не существует устоявшегося способа декодирования, применение для декодирования традиционного классификатора призвано продемонстрировать, что выходные частоты обученной спайковой сети содержат в себе информацию, достаточную для распознавания классов.

Точность классификации оценивается по метрике F1 с применением кросс-валидации: перемешанный случайным образом набор данных делится на 5 частей по 50%, и обучение с тестированием проводилось 5 раз, с обучением каждый раз на новой комбинации 4 частей из 5 (то есть на 80% данных, что составляет по 40 примеров из класса) и тестированием на оставшейся 20%-ной части.

Для сравнения эффективности предложенного алгоритма была также адаптирована для задачи классификации ирисов Фишера другая сеть, предложенная в литературе [7] для решения задачи распознавания рукописных цифр MNIST. Эта сеть состояла из одного слоя возбуждающих нейронов и одного слоя тормозящих нейронов. Каждый возбуждающий нейрон связан непластичным синапсом с одним тормозящим нейроном, который, в свою очередь, своей активностью тормозит все остальные нейроны, кроме своего возбуждающего собрата. STDP-пластичностью обладают входящие синапсы возбуждающих нейронов. В каждом слое было по 100 нейронов. Каждый компонент входного вектора подавался на 25 из 100 входных синапсов нейрона; константы отображения компонента входного вектора в частоту входных спайковых последовательностей были так, чтобы получившиеся входные частоты были близкими к исходной работе [7]: $v_h = 8$ Гц, $v_l = 0$ Гц.

5.3. Результаты

При декодировании классов по выходным частотам обученной спайковой сети с помощью классификатора Decision Tree мера точности F1 составила 91% (в среднем по разбиениям кросс-валидации; стандартное отклонение между разбиениями — 5%, минимальное значение среди разбиений — 83%, максимальное — 97%).

При декодировании с помощью Gradient Boosting средняя F1 составила 93% (стандартное отклонение 5%, минимальная 87%, максимальная 100%).

Сеть с тормозящими связями из литературы показала F1 в 93% (стандартное отклонение меж-

ду разбиениями кросс-валидации — 3%, минимальная 90%, максимальная 97%).

Таким образом, предложенная сеть показывает точность, равную существующим в литературе результатам, используя при этом в два раза меньшее количество нейронов.

6. ЗАКЛЮЧЕНИЕ

Входные синапсы, на которые поступают коррелирующие последовательности спайков, за счет меньшей конкуренции между собой под действием STDP получают преимущество перед входами, на которые поступают независимые пуассоновские последовательности. В результате при достаточно большой корреляции конкуренция между входами оказывается недостаточной для стабилизации выходной частоты.

В двуслойной сети стабилизации выходной частоты нейронов второго слоя можно добиться, уменьшив корреляцию выходных спайков нейронов первого слоя путем увеличения количества их входов.

Обучение на основе STDP двуслойной спайковой сети с использованием предложенного способа размножения входов показывает точность 93%, сравнимую с точностью других подходов к обучению спайковых сетей с частотным кодированием входных данных.

БЛАГОДАРНОСТИ

Авторы благодарны Р.Б. Кошкину и О.А. Щегорцовой за помощь в проведении вычислительных экспериментов.

Численные симуляции проводились с использованием пакета Neural Simulation Tool (NEST) [15].

Работа выполнена с использованием оборудования центра коллективного пользования “Комплекс моделирования и обработки данных исследовательских установок мега-класса” НИЦ “Курчатовский институт”, <http://ckp.nrcki.ru/>.

СПИСОК ЛИТЕРАТУРЫ

1. *Srinjoy Mitra, Stefano Fusi, and Giacomo Indiveri*. Real-time classification of complex patterns using spike-based learning in neuromorphic VLSI. *Biomedical Circuits and Systems, IEEE Transactions on*. 2009. V. 3 (1). P. 32–42.
2. *Paul A. Merolla, John V. Arthur, Rodrigo Alvarez-Icaza, Andrew S. Cassidy, Jun Sawada, Filipp Akopyan, Bryan L. Jackson, Nabil Imam, Chen Guo, Yutaka Nakamura, et al.* A million spiking-neuron integrated circuit with a scalable communication network and interface. *Science*. 2014. V. 345 (6197). P. 668–673.
3. *Thomas Pfeil, Tobias C Potjans, Sven Schrader, Wiebke Potjans, Johannes Schemmel, Markus Diesmann, and Karlheinz Meier*. Is a 4-bit synaptic weight resolution

- enough? – constraints on enabling spike-timing dependent plasticity in neuromorphic hardware. *Frontiers in neuroscience*. 2012. V. 6. P. 90.
4. Steven K. Esser, Paul A. Merolla, John V. Arthur, Andrew S. Cassidy, Rathinakumar Appuswamy, Alexander Andreopoulos, David J. Berg, Jeffrey L. McKinstry, Timothy Melano, Davis R. Barch, et al. Convolutional networks for fast, energy-efficient neuromorphic computing. *Proceedings of the National Academy of Sciences*. 2016. P. 201604850.
 5. Adrian E.D. The basis of sensation. W. W. Norton & Co, 1928.
 6. Morrison A., Diesmann M., and Gerstner W. Phenomenological models of synaptic plasticity based on spike timing. *Biological Cybernetics*. 2008. V. 98. P. 459–478.
 7. Peter U. Diehl and Matthew Cook. Unsupervised learning of digit recognition using Spike-Timing-Dependent Plasticity. *Frontiers in Computational Neuroscience*, 2015.
 8. Сбоев А.Г., Серенко А.В., Рыбка Р.Б., Власов Д.С. Сравнение частотного и временного кодирования данных при решении спайковой сетью со Spike-Timing-Dependent Plasticity задачи классификации. *Вестник национального исследовательского ядерного университета МИФИ*. 2018. Т. 7 (6). С. 563–568.
 9. Richard Kempter, Wulfram Gerstner, and J. Leo van Hemmen. Intrinsic stabilization of output rates by spike-based hebbian learning. *Neural computation*. 2001. V. 13 (12). P. 2709–2741.
 10. Eugene M. Izhikevich and Niraj S. Desai. Relating STDP to BCM. *Neural computation*. 2003. V. 15 (7). P. 1511–1523.
 11. Sboev A., Rybka R., and Serenko A. On the effect of stabilizing mean firing rate of a neuron due to STDP. In J. Kortelainen, A. Bilyatdinova, A. Klimova, and A. Boukhanovsky, editors, 6th International Young Scientist Conference on Computational Science. Elsevier BV, 2017. V. 119. P. 166–173.
 12. Mark C.W. van Rossum, Guo Qiang Bi, and Gina G. Turrigiano. Stable Hebbian learning from Spike Timing-Dependent Plasticity. *Journal of neuroscience*. 2000. V. 20 (23). P. 8812–8821.
 13. Sen Song, Kenneth D. Miller, and Larry F. Abbott. Competitive Hebbian learning through spike-timing-dependent synaptic plasticity. *Nature Neuroscience*. 2000. V. 3 (9). P. 919–926.
 14. Sboev A., Rybka R., Serenko A., Vlasov D., Kudryashov N., and Demin V. To the role of the choice of the neuron model in spiking network learning on base of Spike-Timing-Dependent Plasticity. In V. V. Klimov and A. V. Samsonovich, editors, 8th Annual International Conference on Biologically Inspired Cognitive Architectures. Elsevier BV, 2018. V. 123. P. 432–439.
 15. Susanne Kunkel, Abigail Morrison, Philipp Weidel, Jochen Martin Eppler, Ankur Sinha, Wolfram Schenck, Maximilian Schmidt, Stine Brekke Vennemo, Jakob Jordan, Alexander Peyser, Dimitri Plotnikov, Steffen Graber, Tanguy Fardet, Dennis Terhorst, Håkon Mørk, Guido Trensche, Alex Seeholzer, Rajalekshmi Deepu, Jan Hahne, Inga Blundell, Tammo Ippen, Jannis Schuecker, Hannah Bos, Sandra Diaz, Espen Hagen, Sepehr Mahmoudian, Claudia Bachmann, Mikkel Elle Lepperød, Oliver Breitwieser, Bruno Golosio, Hendrik Rothe, Hesam Setareh, Mikael Djurfeldt, Till Schumann, Alexey Shusharin, Jesús Garrido, Eilif Benjamin Muller, Arjun Rao, Juan Hernandez Vieites, and Hans Ekkehard Plesser. NEST 2.12.0, March 2017.

Vestnik Natsional'nogo issledovatel'skogo yadernogo universiteta "MIFI", 2020, vol. 9, no. 1, pp. 82–90

Effect of Spike Train Correlation on Spiking Neural Network Learning by Spike-Timing-Dependent Plasticity

A. G. Sboev^{a,b,#}, R. B. Rybka^{b,##}, and A. V. Serenko^{b,###}

^a National Research Centre Kurchatov Institute, Moscow, 123182 Russia

^b National Research Nuclear University MEPHI (Moscow Engineering Physics Institute), Moscow, 115409 Russia

[#]e-mail: sag111@mail.ru,

^{##}e-mail: rybkarb@gmail.com,

^{###}e-mail: serenko@phystech.edu

Received December 19, 2019; revised December 19, 2019; accepted January 21, 2020

Abstract—The possibility for a two-layer spiking neural network with spike-timing-dependent plasticity to be trained using the output rate stabilization effect is studied. Numerical simulations show that high correlation of input spike sequences disrupts the stabilization of the neuron spiking rate because of insufficient competition between input synapses. For a two-layer network, shown spikes coming at the input of the second layer can be correlated because the first-layer weights established by STDP partially coincide. In order to stabilize the output rate of the second layer, a method is proposed to reduce the spike correlation of the first layer of the network by increasing the number of input synapses to decrease the similarity of weights established by spike-timing-dependent plasticity in different first-layer neurons. Then, a two-layer network with the multi-

plication of input synapses is shown to be applicable to a toy classification task of Fisher's Iris. The accuracy of classification is obtained to be 93% by F1-score, which is at the level of the existing approaches for training spiking neural networks with rate encoding of the input.

Keywords: spiking neural networks, spike-timing-dependent plasticity, machine learning

DOI: 10.1134/S2304487X20010083

REFERENCES

1. Srinjoy Mitra, Stefano Fusi, and Giacomo Indiveri. Real-time classification of complex patterns using spikebased learning in neuromorphic VLSI. *Biomedical Circuits and Systems, IEEE Transactions on*, 3 (1): 32–42, 2009.
2. Paul A. Merolla, John V. Arthur, Rodrigo Alvarez-Icaza, Andrew S. Cassidy, Jun Sawada, Filipp Akopyan, Bryan L. Jackson, Nabil Imam, Chen Guo, Yutaka Nakamura, et al. A million spiking-neuron integrated circuit with a scalable communication network and interface. *Science*, 345 (6197): 668–673, 2014.
3. Thomas Pfeil, Tobias C. Potjans, Sven Schrader, Wiebke Potjans, Johannes Schemmel, Markus Diesmann, and Karlheinz Meier. Is a 4-bit synaptic weight resolution enough? – constraints on enabling spike-timing dependent plasticity in neuromorphic hardware. *Frontiers in neuroscience*, 6: 90, 2012.
4. Steven K. Esser, Paul A. Merolla, John V. Arthur, Andrew S. Cassidy, Rathinakumar Appuswamy, Alexander Andreopoulos, David J. Berg, Jeffrey L. McKinstry, Timothy Melano, Davis R. Barch, et al. Convolutional networks for fast, energy-efficient neuromorphic computing. *Proceedings of the National Academy of Sciences*, page 201604850, 2016.
5. Adrian E.D. The basis of sensation. W. W. Norton & Co, 1928.
6. Morrison A., Diesmann M., and Gerstner W. Phenomenological models of synaptic plasticity based on spike timing. *Biological Cybernetics*, 98: 459–478, 2008.
7. Peter U. Diehl and Matthew Cook. Unsupervised learning of digit recognition using SpikeTiming-Dependent Plasticity. *Frontiers in Computational Neuroscience*, 2015.
8. Sboev A.G., Serenko A.V., Rybka R.B., and Vlasov D.S., Sravnenie chastotnogo i vremennogo kodirovaniya dannykh pri reshenii spaykovoy set'yu so Spike-Timing-Dependent Plasticity zadachi klassifikatsii. *Vestnik Natsional'nogo issledovatel'skogo yadernogo universiteta MIFI*, 7 (6): 563–568, 2018.
9. Kempter Richard, Gerstner Wulfram, and J. Leo van Hemmen. Intrinsic stabilization of output rates by spikebased hebbian learning. *Neural computation*, 13 (12): 2709–2741, 2001.
10. Eugene M. Izhikevich and Niraj S. Desai. Relating STDP to BCM. *Neural computation*, 15 (7): 1511–1523, 2003.
11. Sboev A., Rybka R., and Serenko A. On the effect of stabilizing mean firing rate of a neuron due to STDP. In J. Kortelainen, A. Bilyatdinova, A. Klimova, and A. Boukhanovsky, editors, 6th International Young Scientist Conference on Computational Science, volume 119, pages 166–173. Elsevier BV, 2017.
12. Mark C.W. van Rossum, Guo Qiang Bi, and Gina G. Turrigiano. Stable Hebbian learning from Spike Timing-Dependent Plasticity. *Journal of neuroscience*, 20 (23): 8812–8821, 2000.
13. Sen Song, Kenneth D. Miller, and Larry F. Abbott. Competitive Hebbian learning through spike-timing-dependent synaptic plasticity. *Nature Neuroscience*, 3 (9): 919–926, 2000.
14. Sboev A., Rybka R., Serenko A., Vlasov D., Kudryashov N., and Demin V. To the role of the choice of the neuron model in spiking network learning on base of Spike-Timing-Dependent Plasticity. In V. V. Klimov and A. V. Samsonovich, editors, 8th Annual International Conference on Biologically Inspired Cognitive Architectures, volume 123, pages 432–439. Elsevier BV, 2018.
15. Susanne Kunkel, Abigail Morrison, Philipp Weidel, Jochen Martin Eppler, Ankur Sinha, Wolfram Schenck, Maximilian Schmidt, Stine Brekke Vennemo, Jakob Jordan, Alexander Peyser, Dimitri Plotnikov, Steffen Graber, Tanguy Fardet, Dennis Terhorst, Håkon Mørk, Guido Trensche, Alex Seeholzer, Rajalekshmi Deepu, Jan Hahne, Inga Blundell, Tammo Ippen, Jannis Schuecker, Hannah Bos, Sandra Diaz, Espen Hagen, Sepehr Mahmoudian, Claudia Bachmann, Mikkel Elle Lepperød, Oliver Breitwieser, Bruno Golosio, Hendrik Rothe, Hesam Setareh, Mikael Djurfeldt, Till Schumann, Alexey Shusharin, Jesu's Garrido, Eilif Benjamin Muller, Arjun Rao, Juan Hernando Vieites, and Hans Ekkehard Plesser. NEST 2.12.0, March 2017.