

ОБУЧЕНИЕ ДЕЙСТВИЯМ ЧЕЛОВЕКА НА ПРОТЯЖЕНИИ ЖИЗНИ ПОСРЕДСТВОМ САМООРГАНИЗУЮЩЕЙСЯ ГЛУБОКОЙ НЕЙРОННОЙ СЕТИ

HUMAN ACTS LEARNING THROUGH LIFELINE BY THE NEURAL NETWORKS WITH THE DEEP SELF-ORGANIZATION

**V. Yulkova
G. Shilovskii**

Summary. If to overview autonomic robots and systems, learning during the lifeline is the basis to replenishing and changing knowledge by means of multiple trials and experience at all. But be that as it may, the standard models of neural motion with deep recognition by video do not take into account training throughout the entire life cycle, but they study pre-defined training data packages with a specified number of samples and classes of actions. And this means that there is a need to create such training systems that can process and adapt the perceptual signals available at the time as they arrive. In this scientific article, we offer you a description of neural architecture with self-organization, capable of a gradual study of the classifications of human actions on video materials. The architecture includes growing networks of self-organization that have reverse neurons for processing dynamically unstable patterns. The method involves sets of reverse networks with hierarchical organization to introduce the possibility of studying the essence of actions with continuously increasing spatio-temporal fields of susceptibility without human control. With the help of neural dynamics, based on predicting the growth and adaptability of reverse networks by determining the ability to reconstruct incoming sequences, arranging them over time, learning is gained throughout life.

Keywords: lifeline learning, motion recognition, deep learning unattended, self-organization.

Юлкова Виктория Михайловна

*К.ф.-м.н., Доцент, Северный (Арктический)
федеральный университет имени М. В. Ломоносова
v.yulkova@narfu.ru*

Шиловский Георгий Владимирович

*Аспирант, НОУ ВО «Институт управления»;
Инженерная компания ООО «Эксперт-Центр»
г. Архангельск
george.shilovskiy@brightapp.team*

Аннотация. Обучение в течение всей жизни является основополагающим в автономной робототехнике для приобретения и корректировки знаний с помощью опыта. Тем не менее, обычные глубокие нейронные модели для распознавания действий из видео не учитывают обучение на протяжении всей жизни, а скорее изучают пакет обучающих данных с заранее определенным количеством классов действий и образцов. Таким образом, существует необходимость в разработке обучающих систем, способных постепенно обрабатывать доступные сигналы восприятия и адаптировать их ответы с течением времени. В данной статье предлагаем вам рассмотреть самоорганизующуюся нейронную архитектуру для постепенного обучения классификации действий человека по видеопоследовательностям. Архитектура включает в себя растущие самоорганизующиеся сети, оснащенные рекуррентными нейронами для обработки изменяющихся во времени шаблонов. Метод использует набор иерархически организованных рекуррентных сетей для неконтролируемого изучения представлений действий с постоянно растущими пространственно-временными восприимчивыми полями. Обучение в течение всей жизни достигается с точки зрения нейронной динамики, основанной на предсказаниях, в которых рост и адаптация рекуррентных сетей определяются их способностью восстанавливать упорядоченные по времени входные последовательности.

Ключевые слова: обучение в течение всей жизни, распознавание действий, глубокое обучение без присмотра, самоорганизующиеся нейронные сети.

Иерархическая организация визуальной коры вдохновила вычислительные модели на распознавание действий из видео, с помощью глубоких архитектур нейронных сетей, предоставляющих современные результаты на наборе эталонных наборов данных.

Как правило, визуальные модели, использующие глубокое обучение, содержат набор уровней свертки и объединения, обученных иерархически для получения представлений элементов действия с возрастающей степенью абстракции [3]. Эта схема обработки согласуется с нейрофизиологическими исследованиями, подтверждающими наличие функциональных иерархий

с постоянно увеличивающимися пространственными и временными рецептивными полями вдоль корковых путей [4, 12]. Было доказано, что подготовка моделей глубокого обучения для последовательностей действий требует больших вычислительных затрат и требует достаточно большого количества обучающих выборок для успешного изучения пространственно-временных фильтров. Кроме того, вышеописанные подходы были разработаны для изучения конкретной серии обучающих действий, таким образом, предполагая именно данный обучающий набор. Этот обучающий набор должен содержать все необходимые знания, которые можно легко использовать для прогнозирования новых образцов. Следовательно, такая схема обучения не подходит для

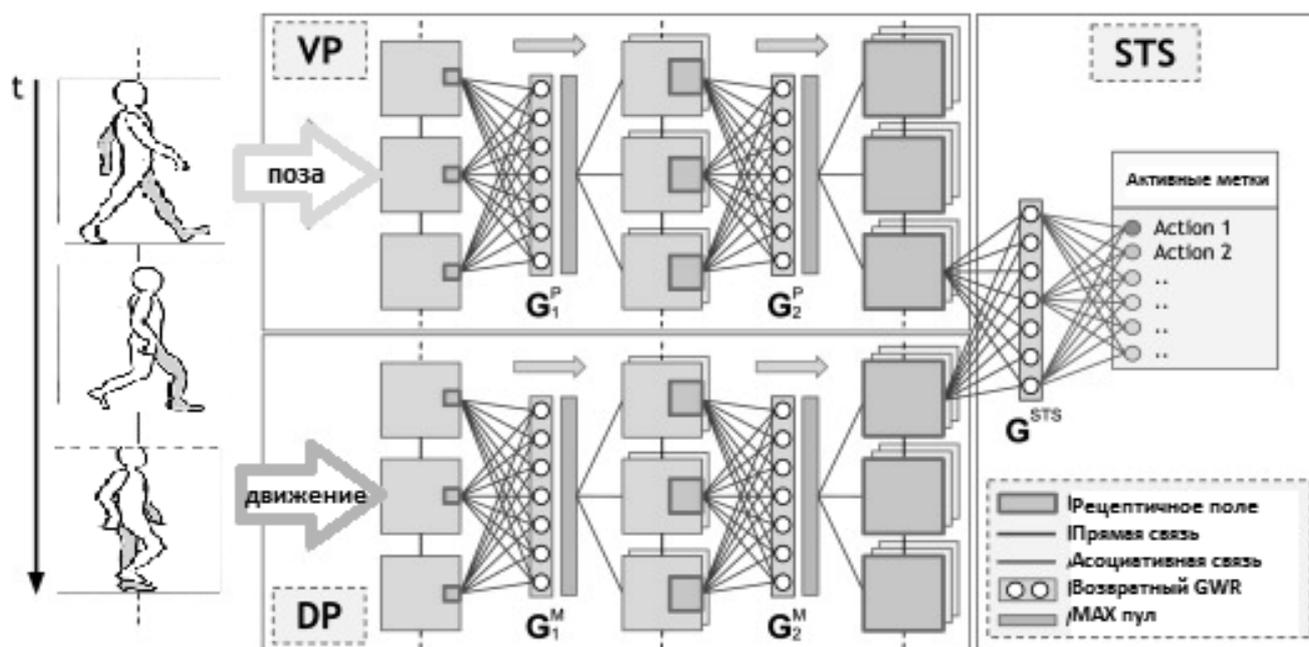


Рис. 1. Схема рассматриваемой глубоко нейронной архитектуры с рекуррентными сетями GWR для распознавания действий.

более естественных сценариев, где искусственный агент должен постепенно обрабатывать набор воспринимаемых сигналов, по мере их поступления.

Таким образом, указанные обстоятельства обуславливают актуальность, теоретическую и практическую значимость выбранной темы исследования.

Обучение в течение всей жизни считается необходимым для когнитивного развития и играет ключевую роль в автономной робототехнике для прогрессивного приобретения знаний через опыт и развитие значимых внутренних представлений в течение обучающих сессий [5, 13]. При работе с нестационарными данными системы обработки должны учитывать интеграцию новой информации при сохранении существующих знаний [2]. Эта проблема известна как дилемма стабильность-пластичность и хорошо изучена как в биологических системах, так и в вычислительных моделях. В частности, цель теорий стабильности-пластичности состоит в том, чтобы избежать катастрофического вмешательства, то есть процесса записи новых знаний, перезаписывающих старые знания. Для управляемых ошибками моделей соединений, таких как сети с обратным распространением, критическое рассеивание может быть устранено путем использования специальных структур обработки [7].

В данной статье мы рассмотрим глубокую нейронную архитектуру для обучения действиям тела в течение всей

жизни и начнем с иерархической нейронной самоорганизации. Данная архитектура состоит из серии иерархически организованных самоорганизующихся нейронных сетей для обработки действий тела по признакам позы-движения (рис. 1). Каждый уровень в иерархии включает в себя рекуррентный вариант сети Growing When Required (GWR) [6], Gamma-GWR и механизм объединения для изучения функций действия со все более большими пространственно-временными рецептивными полями. В последнем слое интегрированы нейронные паттерны активации из разных путей. В целях классификации действий мы предлагаем ассоциативный Gamma-GWR (AG-GWR), чтобы развить связи между визуальными представлениями паттернов позы-движения и символическими метками.

Иерархии обеспечивают удобный компромисс с точки зрения селективности инвариантности путем разложения сложной задачи в иерархию более простых задач [9]. С вычислительной точки зрения иерархическая структура обладает преимуществом повышенной вычислительной эффективности за счет совместного использования функциональных возможностей на нескольких уровнях, например, низкоуровневые сети представляют собой словарь функций, которые могут совместно использоваться несколькими задачами.

Предлагаемая глубокая архитектура состоит из двух отдельных потоков обработки для функций позы и дви-

жения и их последующей интеграции в модель, являющуюся аналогом верхней височной борозды головного мозга (далее STS — superior temporal sulcus). Tan, Singer, Serre, Sheinberg и Poggio [11] показали, что моделирование нейронов STS в виде простой линейной взвешенной суммы входных данных по короткой временной шкале дало хорошее соответствие данным нейронных реакций STS у макака по задаче восприятия движения тела. С вычислительной точки зрения было показано, что раздельная обработка позы тела и особенностей движения улучшает точность распознавания действий. На рис. 1 видим, как сигналы действия позы и движения обрабатываются отдельно в вентральном (VP) и дорсальном путях (DP), соответственно. Каждая сеть состоит из рекуррентной конкурентной сети. На этапе STS рекуррентная сеть GWR изучает ассоциативные связи между представлениями действий прототипа и символическими метками.

Рассмотрим временную сеть GWR, Gamma-GWR, которая снабжает каждый нейрон произвольным числом контекстных дескрипторов для увеличения глубины памяти и временного разрешения в духе модели гамма-памяти [1]. Далее произойдет модификация функции активации модели GWR и правила обучения, чтобы учесть пространственно-временную обработку с использованием гамма-фильтрации.

Сеть GWR снабжается рекуррентными нейронами, следуя соответствующим формулировкам контекстного обучения [10], так что наиболее подходящий нейрон w_b для входа $x(t)$ вычисляется следующим образом:

$$b = \arg \arg \{d_i\}, \tag{1}$$

$$d_i = \alpha_\omega \cdot \|x(t) - w_i\|^2 + \sum_{k=1}^K \alpha_k \cdot \|C_k(t) - c_i^k\|^2, \tag{2}$$

$$C_k(t) = \beta \cdot w_{b(t-1)} + (1 - \beta) \cdot c_{b(t-1)}^{k-1}, \tag{3}$$

для каждого $k = 1, \dots, K$, где $\alpha, \beta \in (0; 1)$ — постоянные значения, которые модулируют влияние входного тока и прошлых активаций, $b(t-1)$ является индексом наиболее подходящего нейрона в момент времени $t-1$, а $c_{b(t-1)}^0 = w_{b(t-1)}$. Эта формулировка изучения контекста сочетает в себе компактную обратную ссылку на предыдущий нейрон с наилучшим соответствием с отдельно контролируемым вкладом текущего ввода и прошлого с произвольной сетевой топологией. Для инициализации сети необязательно иметь серию обучающих образцов. Вместо этого нейроны постепенно создаются и настраиваются со временем. Таким образом, мы инициализируем наши дескрипторы контекста $c_{b(0)}^k = 0$. Для $K = 1$, то есть только одного контекстного дескриптора, Gamma-GWR сводится к временному GWR, как представлено у Parisi, Strickert и Hammer [8, 10] которые показали, что SOM с контекстным обучением сходится

к эффективному фрактальному кодированию заданных последовательностей с высокой точностью временного квантования.

Функция затухания с уменьшением значений параметра α_i постепенно пропускает экспоненциально меньшее количество входных данных с течением времени. Поскольку определение дескрипторов контекста является рекурсивным, было показано, что установка $\alpha_\omega > \alpha_1 > \dots > \alpha_{k-1} > \alpha_k > 0$ уменьшает распространение ошибок от ранних стадий фильтрации до контекстов более высокого порядка для Gamma-SOM и Gamma-GNG.

Обучение выполняется путем адаптации веса и векторов контекста наиболее подходящих нейронов и их соседей в соответствии с

$$\Delta w_i = \epsilon_i \cdot \eta_i \cdot (x(t) - w_i), \tag{4}$$

$$\Delta c_i^k = \epsilon_i \cdot \eta_i \cdot (C_k(t) - c_i^k), \tag{5}$$

где ϵ_i — скорость обучения, которая модулирует обновление нейронов. В отличие от SOM, скорость обучения не уменьшается со временем. Вместо этого счетчик срабатывания η_i используется для модуляции объема обучения. Счетчик запуска нейрона i инициализируется на 1 и уменьшается в соответствии со следующим правилом привыкания [6]:

$$\Delta \eta_i = \tau_i \cdot k \cdot (1 - \eta_i) - \tau_i, \tag{6}$$

где k и τ_i — константы, управляющие поведением кривой. Этот механизм заставляет нейроны, которые запускаются чаще, обучаться меньше, тем самым способствуя конвергенции сети и в некоторой степени напоминая SOM-подобные реализации, которые постепенно уменьшают ширину ядра функции соседства и скорость обучения. Следует отметить, что, в отличие от SOM, топология сети GWR не является фиксированной, а скорее развивается со временем после обучения, подобного Хеббовскому обучению, то есть нейроны, которые совместно активируются, связаны друг с другом. В отличие от стандартного GWR (где активация сети $\alpha_t = \exp \exp (-\|x(t) - w_b\|)$), в Gamma-GWR эта функция заменяется на $\alpha_t = \exp \exp (-d_b)$, с d_b , как определено в формуле (2).

Возвращаясь к тематике обучения в течение всей жизни. В растущих самоорганизующихся сетях, таких как GWR [6], могут быть созданы доступные ресурсы для выделения новой информации с точки зрения новых нейронов и сетевых соединений, обусловленных распределением входных данных. С использованием иерархических сетей Gamma-GWR, как описано ранее,

обучение в течение всей жизни может быть достигнуто с точки зрения нейронной динамики, основанной на предсказаниях. Чтобы распределить ресурсы для новой информации, рост сетей модулируется их способностью восстанавливать шаблоны нейронной активации из предыдущего сетевого уровня.

Учитывая два смежных сетевых уровня G^{L-1} и G^L в рассматриваемой архитектуре, нейронные активации из G^{L-1} отправляются в G^L через соединения с прямой связью. Нейронный рост в алгоритме обучения модулируется способностью G^L восстанавливать последовательности активации из G^{L-1} . Учитывая наиболее подходящий нейрон w_b для текущего входа $x(t)$, как определено минимальным расстоянием в формуле (1) активация сети вычисляется как $\alpha(t) = \exp \exp(-d_b(t))$, и счетчик запуска η_b нейрона обновляется. Новый нейрон будет добавлен, когда $\alpha(t) > \alpha_T$, и $\eta_b > f_T$, где α_T — порог активации, который устанавливает максимальное расхождение (расстояние) между входной последовательностью из G^{L-1} и ее наиболее подходящим нейроном в G^L . Следовательно, $\alpha(t)$ можно рассматривать как ошибку предсказания последовательностей нейронной активации в G^L , которые восстанавливают последовательности прототипа из G^{L-1} , так что каждая сеть более высокого уровня может научиться периодически восстанавливать входные последовательности из сетей более низкого уровня. Порог срабатывания f_T гарантирует, что существующие нейроны обучаются перед выделением новых, тем самым обеспечивая точную настройку топологической карты.

Самоорганизующаяся динамика обучения иерархии учитывает предотвращение катастрофических помех путем обновления нейронов в соответствии с конкурентным обучением по хеббам, чтобы они представляли новую информацию на основе ее сходства с существующими знаниями или путем выделения новых нейронов всякий раз, когда существующие недостаточно представляют новую информацию.

Когда нейрон срабатывает, возраст соединений от нейрона к его топологическим соседям устанавливается равным 0, в то время как возраст остальных соединений увеличивается на значение 1. Таким образом, механизм возраста соединения используется для контроля надежности информации в растущей сети.

Теперь рассмотрим объединение слоев. Вычислительные модели с глубокой архитектурой получают инвариантные отклики путем чередования слоев детекторов признаков и нелинейных пулирующих нейронов с использованием операции максимальной (MAX), которая, как было показано, обеспечивает более высокую специфичность признаков и более устойчивую инвариантность по отношению к линейному суммированию.

В рассматриваемой архитектуре реализуются уровни пула MAX после каждого конкурентного уровня (Рис. 1). Для каждого патча входного изображения наилучший совпадающий нейрон $w_b^{(n-1)} \in R^m$ будет вычислен в конкурентном слое $(n-1)$, и только его максимальное значение веса $\tilde{w}^{(n)} \in R$ передается следующему уровню n :

$$\tilde{w}^{(n)} = w_{b,i}^{(n-1)}, \quad (7)$$

где b вычисляется по формуле (1). Верхний индекс тильды на $\tilde{w}^{(n)}$ указывает, что это значение не является фактическим нейронным весом слоя n , а скорее объединенным значением активации из слоя $(n-1)$, которое будет использоваться в качестве входных данных в слое n для изучения нейронных весов прототипа. Поскольку пространственное восприимчивое поле нейронов увеличивается вдоль иерархии, этот процесс объединения даст масштаб и положение инвариантности.

Далее рассмотрим ассоциативное обучение и классификацию. Целью классификации является прогнозирование меток действий из невидимых образцов действий. Для этой цели последняя сеть G^{STS} оснащена ассоциативным механизмом обучения для сопоставления меток образцов с прототипами нейронов, представляющих сегменты действия.

На этапе обучения нейронам в G^{STS} можно присвоить метку l (с l из набора L классов меток) или оставить без метки. Ассоциативная матрица $H(i, l)$ хранит частотное распределение меток выборки в сети, т.е. каждый нейрон i хранит количество раз, которое данная выборка метки $l \in L$ была связана с ее нейронным весом. Эта стратегия маркировки не требует заранее определенного количества классов действий. Когда новый нейрон r создан и при условии, что ξ является меткой входного образца $x(t)$, ассоциативная матрица H увеличивается на одну строку и инициализируется в соответствии с $H(r, \xi) = 1$ и

$$H(r, l) = 0 \text{ при } l \in \frac{L}{\{\xi\}}.$$

Когда вместо этого обновляется существующий наиболее подходящий нейрон b , мы увеличиваем $H(b, \xi)$ на величину δ^+ и уменьшаем $H(b, l)$ на δ^- где $\delta^+ > \delta^-$. Если метка выборки ξ отсутствует в L , создается новый столбец в H и инициализируется $H(b, \xi) = 1$ и $H(b, l) = 0$, тогда как если входная выборка не помечена, то H не обновляется.

Этот механизм маркировки дает нейроны, связанные с наиболее часто встречающимися метками, таким образом, также обрабатывая ситуации, в которых образцы меток могут иногда отсутствовать или повреждаться. Нейроны в сети G^{STS} активируются последними входными

ми выборками $K + 1$, то есть от времени t до $t - K$. Метка, которую мы принимаем во внимание, является одной из самых последних входных данных $x(t)$. Чтобы предсказать метку λ нового образца $\tilde{x}(t)$ после завершения обучения, мы вычисляем класс меток с наибольшим значением ассоциативной матрицы для наиболее подходящего нейрона b в $\tilde{x}(t)$ как $\lambda = \arg \arg \max_{l \in L} H(b, l)$.

Таким образом, в отличие от подходов пакетного обучения, обучение на протяжении всей жизни имеет решающее значение для постепенного развития знаний, основанных на прогрессивно доступных способах восприятия. В этой статье мы показали, что обучение в течение всей жизни может развиваться с точки зрения управляемой предсказанием нейронной динамики с представлениями действий, возникающими

в иерархии самоорганизующихся нейронных сетей. Рассмотренная модель обучения демонстрирует конкурентоспособную производительность по сравнению с современными моделями глубокого обучения, обученными с заранее определенным количеством классов действий, демонстрируя устойчивую производительность даже в случае отсутствия или повреждения меток выборки и адаптации к нестационарным входным распределениям.

Предложенную архитектуру можно считать дальнейшим шагом к созданию более гибких моделей нейронных сетей способных обучаться более правдоподобным и надежным визуальным воспроизведениям, которые развиваются и настраиваются с течением времени на основе визуального опыта.

ЛИТЕРАТУРА

1. de Vries B., Principe J. C. The gamma model—A new neural model for temporal processing / *Neural Networks*, 5 (4) (1992), pp. 565–576.
2. Grossberg S. Competitive learning: From interactive activation to adaptive resonance / *Cognitive Science*, 11 (1) (1987), pp. 23–63, 10.1016/S0364-0213(87)80025-3.
3. Guo Y., Liu Y., Oerlemans A., Lao S., Wu S., Lew M. S. Deep learning for visual understanding: A review / *Neurocomputing*, 187 (2016), pp. 27–48, 10.1016/j.neucom.2015.09.116, Recent Developments on Deep Big Vision.
4. Hasson U., Yang E., Vallines I., Heeger D. J., Rubin N. A hierarchy of temporal receptive windows in human cortex / *The Journal of Neuroscience*, 28 (10) (2008), pp. 2539–2550, 10.1523/jneurosci.5487-07.2008.
5. Lee J. Cumulative learning / *Encyclopedia of the sciences of learning*, Springer US, Boston, MA (2012), pp. 887–893, (Chapter).
6. Marsland S., Shapiro J., Nehmzow U. A self-organising network that grows when required / *Neural Networks*, 15 (8–9) (2002), pp. 1041–1058.
7. McClelland J. L., McNaughton B. L., O'Reilly R. C. Why There are Complementary Learning Systems in the Hippocampus and Neocortex: Insights from the successes and failures of connectionist models of learning and memory / *Psychological Review*, 102 (1995), pp. 419–457.
8. Parisi, G. I., Magg, S., & Wermter, S. (2016). Human motion assessment in real time using recurrent self-organization. In *Proc. of the IEEE international symposium on robot and human interactive communication, RO-MAN* (pp. 71–76). New York, US.
9. Poggio T., Smale S. The mathematics of learning: Dealing with data / *Notices of the American Mathematical Society*, 50 (2003), p. 2003.
10. Strickert M., Hammer B. Merge SOM for temporal data / *Neurocomputing*, 64 (2005), 10.1016/j.neucom.2004.11.014.
11. Tan, C., Singer, J. M., Serre, T., Sheinberg, D., & Poggio, T. A. (2013). Neural representation of action sequences: how far can a simple snippet-matching model take us? In *Advances in neural information processing systems 26: 27th Annual conference on neural information processing systems 2013. Proceedings of a meeting held December 5–8, 2013, Lake Tahoe, Nevada, United States*. (pp. 593–601).
12. Taylor P., Hobbs J. N., Burrone J., Siegelmann H. T. The global landscape of cognition: hierarchical aggregation as an organizational principle of human cortical networks and functions / *Scientific Reports*, 5 (18112) (2015), 10.1038/srep18112.
13. Zhou H. H. CSM: A computational model of cumulative learning / *Machine Learning*, 5 (4) (1990), pp. 383–406.

© Юлкова Виктория Михайловна (v.ulkoval@narfu.ru), Шиловский Георгий Владимирович (george.shilovskiy@brightapp.team).

Журнал «Современная наука: актуальные проблемы теории и практики»