

АНАЛИЗ МЕТОДОВ ГЛУБОКОГО ОБУЧЕНИЯ ДЛЯ ЗАДАЧ ТАКТИЛЬНОГО ИНТЕРНЕТА

Р. В. Киричек^{1*}, Д. А. Наумкин¹, В. С. Усс¹

¹СПбГУТ, Санкт-Петербург, 193232, Российская Федерация

* Адрес для переписки: kirichek@sut.ru

Аннотация

Концепция Тактильного Интернета получает все большую популярность, в особенности с распространением сетей 5G. Одним из основных требований при создании систем Тактильного Интернета является обеспечение круговой задержки передачи не более 1 мс, при превышении которой у пользователя возникнут сложности при удаленном управлении и восприятии тактильных данных. Поскольку задержки большие 1 мс остаются достаточно частым явлением, возникает необходимость компенсировать утраченные данные и данные, пришедшие с задержкой, используя методы прогнозирования. **Предмет исследования.** В статье проводится анализ наиболее распространенных архитектур нейронных сетей в рамках решения задачи о прогнозировании траектории движения роботизированной системы и выбор наиболее подходящей. **Метод.** Рассмотрены принципы организации и взаимодействия слоев в различных архитектурах. Также сравниваются способы обучения нейронных сетей. **Основные результаты.** Проведено сравнение архитектур нейронных сетей, и даны рекомендации по выбору сети и метода обучения в зависимости от задачи. **Практическая значимость.** Описанные методы позволяют значительно быстрее обучить нейросеть и сделать её предсказания более точными.

Ключевые слова

Тактильный Интернет, Интернет Навыков, обучение с подкреплением, глубокое обучение, нейронные сети, минимальная задержка.

Информация о статье

УДК 004.896

Язык статьи – русский.

Поступила в редакцию 01.11.17, принята к печати 01.12.17.

Ссылка для цитирования: Киричек Р. В., Наумкин Д. А., Усс В. С. Анализ методов глубокого обучения для задач Тактильного Интернета // Информационные технологии и телекоммуникации. 2017. Том 5. № 4. С. 42–48.

DEEP LEARNING METHODS ANALYSIS FOR TACTILE INTERNET TASKS

R. Kirichek^{1*}, D. Naumkin¹

¹ SPbSUT, St. Petersburg, 193232, Russian Federation
 * Corresponding author: kirichek@sut.ru

Abstract—The concept of Tactile Internet is gaining popularity, especially with the spread of 5G networks. One of the main requirements for Tactile Internet systems is to ensure a round-trip delay to be less than 1 ms. Otherwise, the user will have difficulties with remote control and perception of tactile data. Since delays greater than 1 ms remain quite frequent, it becomes necessary to compensate for lost and delayed data using prediction methods. **Research subject.** The article analyzes the most common neural network architectures in the context of solving the problem of predicting the trajectory of a robotic system and choosing the most suitable one. **Method.** The principles of organization and interaction of layers in various architectures are discussed. Also, the methods of learning are compared. **Core results.** The architectures of neural networks are compared, and recommendations are given on the choice of the network and the learning method, depending on the task. **Practical relevance.** The described methods make it possible to train the network more quickly and make its predictions more accurate.

Keywords—Tactile Internet, Internet of Skills, reinforcement learning, deep learning, neural networks, minimal latency.

Article info

Article in Russian.

Received 01.11.17, accepted 01.12.17.

For citation: Kirichek R., Naumkin D., Uss V.: Deep learning methods analysis for Tactile Internet tasks // Telecom IT. 2017. Vol. 5. Iss. 4. pp. 42–48 (in Russian).

Введение

Для описания работы каждого метода можно рассмотреть систему, в которой передающая сторона отправляет координаты человеческой руки в трехмерном пространстве, а принимающая сторона на основе этих данных управляет антропоморфной роботизированной рукой (рис. 1) [1, 2].

При сильной загруженности среды передачи часть координат будет теряться или приходить с задержкой, в результате чего движения роботизированной руки станут прерывистыми, что может нанести вред оборудованию и персоналу, работающему совместно с ней [3].

Можно попытаться предсказать будущее положение руки на основе предыдущих и заменять реальные данные на предсказанные, как только приемная сторона перестает получать обновления координат в ключевые моменты времени. Наиболее очевидным является использование фильтра Калмана или схожих методов, основанных на том, что известна динамическая модель системы (например, физический закон движения) [4], однако при использовании предсказательной системы в различной среде и с различным оборудованием динамическую модель также придется перестраивать, а учитывая большое количество степеней

свободы человеческой руки, то хотелось бы иметь метод с более быстрой адаптацией к окружающим условиям и, возможно, подстраивающейся под конкретного пользователя.

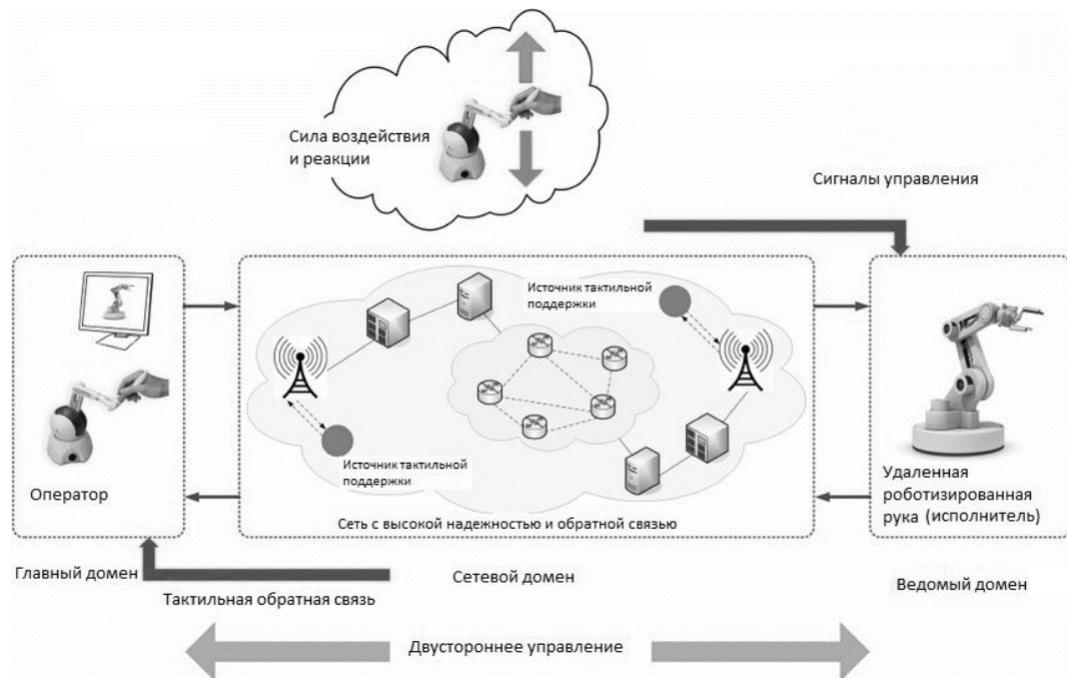


Рис. 1. Пример задачи Тактильного Интернета
 (Image: Realizing The Tactile Internet: Haptic Communications over Next Generation 5G Cellular Networks Article in IEEE Wireless Communications December 2015)

Использование нейронных сетей

Нейронные сети могут значительно уменьшить временные затраты на получение модели. Для этого, имея по одной сети для каждой координатной оси, можно обучить на их наборе данных, в котором каждому вектору, содержащему координаты предыдущего движения, будут сопоставляться следующие координаты. После подстройки весов при обучении сеть сможет предсказывать следующее положение каждого элемента руки на определенной оси. При этом можно увеличить количество нейронов на входном и выходном слое для предсказания более длительной последовательности [5].

Но традиционные нейронные сети сложно применить для анализа временных последовательностей, поскольку размер входного слоя фиксирован, а размер последовательности может быть в несколько раз больше (в случае, когда последовательность меньше входного слоя, неинициализированные нейроны можно заполнить нулями) (рис. 2).

Несмотря на некоторые способы сжатия последовательности для использования традиционной нейросети [6], остается проблема учета предыдущего опыта. Модель для анализа последовательностей должна уметь запоминать предыдущий опыт, оказывающий непосредственное влияние в будущем обучении.

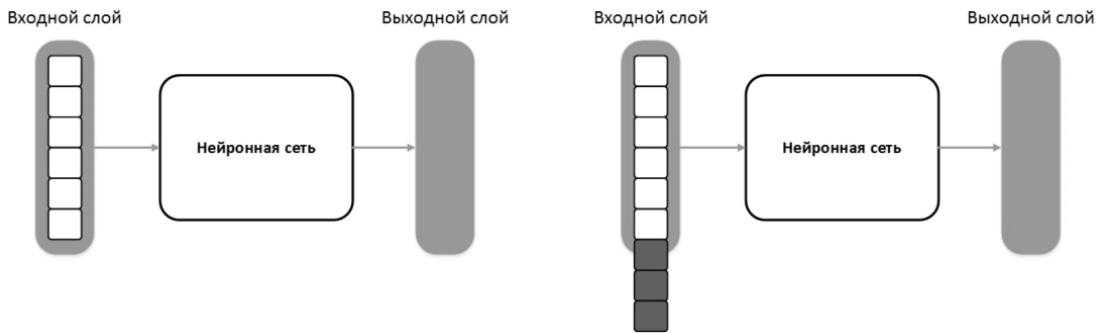


Рис. 2. Фиксированный входной слой классических нейросетей

Примером таких сетей являются рекуррентные нейронные сети (РНС) (рис. 3). В них имеется дополнительный слой, нейроны в котором помимо соединений с предыдущими и последующими слоями имеют соединения, распространяющие информацию между нейронами этого же слоя (включая себя). В результате рекуррентные соединения будут представлять информацию предыдущего шага. Более того, было доказано, что РНС может найти любую функциональную зависимость между входными и выходными данными [7].

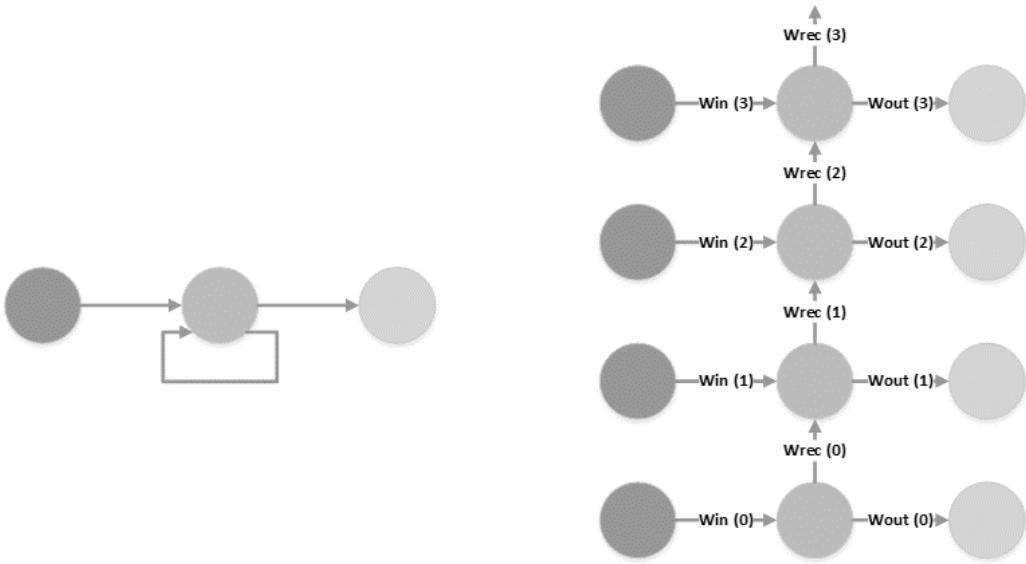


Рис. 3. Нейронная сеть с одним рекуррентным слоем в развернутом виде

Также при реализации данной сети для компенсации задержки передачи необходимо использование известного метода долгой краткосрочной памяти (LSTM), решающего проблему исчезающего градиента, не позволяющего запоминать долгосрочные зависимости, поскольку задержки при передаче могут значительно варьироваться.

Обучение с подкреплением и имитационное обучение

Часто используемым методом обучения в робототехнике является обучение с подкреплением [8]. Основное отличие от методов обучения с учителем в том, что сеть обучается методом проб и ошибок на основе взаимодействия со средой.

После каждого эпизода взаимодействия сеть может получить награду, если действие было удачным. Можно определить этот процесс как марковский процесс принятия решений:

$$\langle S, A, R, T, \gamma \rangle,$$

где S – набор состояний системы, A – набор действий, R – функция наград:

$$R(s, a) : S \times A \rightarrow \mathbb{R},$$

T – функция перехода:

$$T(s, a, s') = p(s' | a, s)$$

γ определяет насколько удаленной награде мы стремимся.

Политикой называется функция, которая возвращает действие при заданном состоянии. Задачей обучения является найти политику, которая бы максимизировала сумму текущей и всех взвешенных будущих наград.

$$J = E\{\sum_{h=0}^{\infty} \gamma^h R_h\}.$$

При этом, если дополнительно передавать координаты руки по параллельному каналу с гарантией доставки, можно будет, хоть и с некоторой задержкой, выдавать награду за совершенное действие на основе сравнения предсказанной и реальной траектории.

Основной проблемой методов обучения с подкреплением является возможная удаленность награды, однако в случае с предсказанием небольшой последовательности во время ожидания доставки данных она не является критичной. Но принцип проб и ошибок порождает другую проблему, связанную с длительностью обучения.

В тоже время имитационное обучения не только поможет решить проблемы неэффективности выборки или вычислительных возможностей, но и сможет сделать процесс обучения более безопасным, поскольку позволит избежать негативных последствий неконтролируемых действий интеллектуальной системы [9].

В имитационном обучении предполагается, что эксперт, которому мы хотим подражать демонстрирует исполнение задания. Но так как ученику последовательно предоставляются правильные траектории, неправильная интерпретация их учеником может привести к неправильным предсказаниям. Такие проблемы нарушают изначальное предположение в независимости примеров, необходимых для обучения с учителем. Поэтому при имитационном обучении необходимо постоянное взаимодействие между учителем и учеником.

Нейронные эхо-сети

Основной проблемой сетей с прямым распространением, к которым относятся все вышеперечисленные, является длительность их обучения из-за большого количества весовых коэффициентов. Ее можно решить путем использования эхо-сетей (*Echo State Networks*), в которых обучаются только коэффициенты нейронов выходного слоя [10].

Эхо-сети являются нестандартной архитектурой РНС (рис. 4). В ней редко связанные рекуррентные нейроны образуют большой «резервуар». Соединения в резервуаре случайно создаются один раз на все время работы и после весовые коэффициенты, отвечающие за соединение нейронов резервуара, не обучаются. А поскольку нейроны рекуррентные, состояния резервуара сохраняются на некоторое время. Как только были использованы все тренировочные сети, применяется линейная регрессия между сохраненными состояниями резервуара и целевыми выходами.

Идея состоит в том, что редкие случайные соединения в резервуаре позволяют предыдущим состояниям «восстановиться», если входные значения похожи на те, на которых сеть тренировалась, так как будет повторяться та же траектория активации. С таким подходом на тренировку затрачивается минимальное время, поскольку большинство весов устанавливаются единожды и случайно.

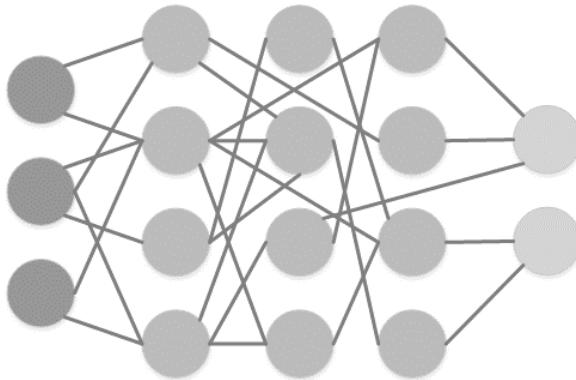


Рис. 4. Пример архитектуры эхо-сети

Заключение

На основе рассмотренных методов можно сделать вывод, что будущие исследования будут проводиться на основе рекуррентных сетей. Так как целью дальнейших исследований является предсказание небольшого участка траектории с требованием к быстрому обучению следует рассматривать варианты, основанные на имитационном обучении с как можно более разнообразной выборкой.

Литература

1. Кучерявый А. Е., Маколкина М. А., Киричек Р. В. Тактильный интернет. Сети связи со сверхмалыми задержками // Электросвязь. 2016. № 1. С. 44–46.
2. Кучерявый А. Е., Владыко А. Г., Киричек Р. В., Маколкина М. А., Парамонов А. И., Выборнова А. И., Пирмагомедов Р. Я. Перспективы научных исследований в области сетей связи на 2017–2020 годы // Информационные технологии и телекоммуникации. 2016. Т. 4. № 3. С. 1–14.
3. Губская О. А., Алисевич Е. А., Кулик В. А. и др. Программно-аппаратный комплекс для тестирования качества услуг связи на базе рекомендации МСЭ-Т Q.3960 // Электросвязь. 2017. № 8. С. 25–32.
4. Belokon' S. A. et al. Using the Kalman filter in the Quadrotor Vehicle Trajectory Tracking System // Optoelectronics, Instrumentation and Data Processing. 2013. Vol. 49. Iss. 6. pp. 536–545.
5. Payeur P., Le-Huy H., Gosselin C. M. Trajectory Prediction for Moving Objects using Artificial Neural Networks // IEEE Transactions on Industrial Electronics. 1995. Vol. 42. Iss. 2. pp. 147–158.
6. Hinton G. E. Reducing the Dimensionality of Data with Neural Networks // Science. 2006. Vol. 313. Iss. 5786. pp. 504–507.
7. Kilian J., Siegelmann H. T. The Dynamic Universality of Sigmoidal Neural Networks // Information and Computation. 1996. Vol. 128. Iss. 1. pp. 48–56.

8. Bagnell A. J. Reinforcement Learning in Robotics: A Survey // Springer Tracts in Advanced Robotics. 2014. Vol. 97. pp. 9–67.
9. Zhang T., McCarthy Z., Jow O., Lee D., Goldberg K., Abbeel P. Deep Imitation Learning for Complex Manipulation Tasks from Virtual Reality Teleoperation // arXiv preprint. 2017.
10. Szita I., Gyenes V., Lőrincz A. Reinforcement Learning with Echo State Networks // International Conference on Artificial Neural Networks. 2006. pp. 830–839.

References

1. Koucheryavy A., Makolkina M., Kirichek R. Tactile Internet. Ultra-Low Latency Networks // Electrosvyaz'. 2016. No. 1. pp. 44–46.
2. Koucheryavy A., Vladyko A., Kirichek R., Makolkina M., Paramonov A., Vybornova A., Pirmagomedov R.: The Prospects for Research in the Field of Communications Networks on the 2017–2020 Years // Telecom IT. 2016. Vol. 4. Iss. 3. pp. 1–14. (in Russian).
3. Gubskaya O., Alisevich E., Kulik V. et al. Software-Hardware Complex for Communication Quality Testing on the basis of ITU-T Q.3960 Recommendation // Electrosvyaz'. 2017. No. 8. pp. 25–32.
4. Belokon' S. A. et al. Using the Kalman filter in the Quadrotor Vehicle Trajectory Tracking System // Optoelectronics, Instrumentation and Data Processing. 2013. Vol. 49. Iss. 6. pp. 536–545.
5. Payeur P., Le-Huy H., Gosselin C. M. Trajectory Prediction for Moving Objects using Artificial Neural Networks // IEEE Transactions on Industrial Electronics. 1995. Vol. 42. Iss. 2. pp. 147–158.
6. Hinton G. E. Reducing the Dimensionality of Data with Neural Networks // Science. 2006. Vol. 313. Iss. 5786. pp. 504–507.
7. Kilian J., Siegelmann H. T. The Dynamic Universality of Sigmoidal Neural Networks // Information and Computation. 1996. Vol. 128. Iss. 1. pp. 48–56.
8. Bagnell A. J. Reinforcement Learning in Robotics: A Survey // Springer Tracts in Advanced Robotics. 2014. Vol. 97. pp. 9–67.
9. Zhang T., McCarthy Z., Jow O., Lee D., Goldberg K., Abbeel P. Deep Imitation Learning for Complex Manipulation Tasks from Virtual Reality Teleoperation // arXiv preprint. 2017.
10. Szita I., Gyenes V., Lőrincz A. Reinforcement Learning with Echo State Networks // International Conference on Artificial Neural Networks. 2006. pp. 830–839.

Наумкин Дмитрий Александрович

– студент, СПбГУТ, Санкт-Петербург, 193232, Российская Федерация, dustedduke@gmail.com

Киричек Руслан Валентинович

– кандидат технических наук, доцент, СПбГУТ, Санкт-Петербург, 193232, Российская Федерация, kirichek@sut.ru

Усс Владимир Станиславович

– кандидат технических наук, доцент, СПбГУТ, Санкт-Петербург, 193232, Российская Федерация, Uss_w@mail.ru

Naumkin Dmitry

– Student, SPbSUT, St. Petersburg, 193232, Russian Federation, dustedduke@gmail.com

Kirichek Ruslan

– Candidate of Engineering Sciences, Associate Professor, SPbSUT, St. Petersburg, 193232, Russian Federation, kirichek@sut.ru

Uss Vladimir

– Candidate of Engineering Sciences, Associate Professor, SPbSUT, St. Petersburg, 193232, Russian Federation, Uss_w@mail.ru