



Ссылка на статью:

// Ученые записки УлГУ. Сер. Математика и информационные технологии. УлГУ. Электрон. журн. 2019, № 2, с. 36-53.

Поступила: 01.11.2019

Окончательный вариант: 28.11.2019

© УлГУ

УДК 519.6

Нейросетевые технологии построения интеллектуальных систем управления роботами

Кожевников В.В.^{1,*}, Леонтьев М.Ю.^{1,2},
Приходько В.В.¹, Сергеев В.А.², Фомин А.Н.¹

[*yvk28061955@mail.ru](mailto:yvk28061955@mail.ru)

¹УлГУ, Ульяновск, Россия

²УФирЭ РАН, Ульяновск, Россия

Основные направления разработки методов проектирования интеллектуальных систем управления роботами предполагают технологии, основанные на использовании искусственных нейронных сетей. Нейронные сети, в которых модель нейрона была разработана как простейший элемент процессора, выполняющий вычисление передаточной функции скалярного произведения вектора входных данных и вектора весовых коэффициентов, могут дать интересные результаты, касающиеся генерации зависимостей и прогнозирования. Однако их очевидным недостатком является отсутствие явного алгоритма действия. Запоминание информации в процессе обучения происходит неявно в результате выбора весовых коэффициентов нейронной сети, поэтому проблема познания (формирования новых знаний) на основе тех знаний, которые были получены ранее в процессе обучения, представляется неразрешимой. Положительное решение этой проблемы откроет путь к созданию полноценного искусственного разума. С этой точки зрения перспективным направлением является то, где математическая модель нейронных сетей строится на основе математической логики.

Ключевые слова: интеллектуальная система управления, роботы, когнитивный автомат, нейронные сети управляемости.

Введение

Поиск перспективных подходов к увеличению производительности современных роботизированных технологических комплексов (РТК) на основе использования манипуляционных роботов определяет необходимость в новых методах разработки их устройств управления. Возрастающая сложность задач, которые ставятся перед роботами в совре-

менном производстве (адаптация к изменяющимся нетривиальным образом состояниям среды, самообучение в процессе работы и т.п.) снижает эффективность жестких детерминированных алгоритмов управления [1].

Перспективным представляется направление построения систем управления роботами основанное на использовании методов искусственного интеллекта [3,17]. Наличие интеллекта определяется возможностью генерации (принятия) эффективных управляющих решений, не предусмотренных логикой, сформированной математиками и программистами. В условиях неопределенности входных воздействий на систему управления, т.е. в ситуации, когда система управления не обучена реакции на входное воздействие, решение принимается в результате генерации новых знаний (генерации логики) на базе знаний, полученных в процессе обучения (синтеза логики).

Главной особенностью интеллектуальных систем является способность решать слабо структурированные и плохо формализованные задачи [2]. При этом важными показателями интеллектуального уровня системы управления является уровень обобщения моделей внешней среды, на основании которых происходит оценка конкретных ситуаций и прогнозирование их развития, а также возможности самоусовершенствования, в том числе при активном взаимодействии для этого с внешней средой. Поэтому в робототехнике наиболее перспективными оказались системы, обучающиеся с подкреплением, которые позволяют автоматически формировать поведение робота во взаимодействии с внешней средой, в которой имеются препятствия или другие роботы [12].

Теоретические и особенно прикладные основы построения интеллектуальных систем управления (ИСУ) еще далеки от завершения, в том числе в части систем контроля и управления сложными техническими и человеко-техническими объектами, включающих искусственные нейронные сети и экспертные системы, функционирующих в затрудненных условиях. Под затрудненными условиями понимается большая размерность объекта управления, его нестационарность, долговременная динамическая память, распределенность параметров, нелинейность, существенные запаздывания, разнообразие ситуаций, неполнота контроля внешних воздействий, выходных воздействий и состояний объекта, наличие флуктуационных и грубых помех, изменчивость целей, критериев, ограничений. Современные промышленные машины, агрегаты, технологические линии, участки, цехи горнодобывающей, металлургической, химической, ядерной, машиностроительной и других отраслей промышленности в большинстве своем относятся к классу сложных объектов. Существенного повышения эффективности управления ими можно достигнуть путем применения адекватно сложных информационно-управляющих систем, какими и являются интеллектуальные системы [15].

Эволюция представлений о путях развития робототехники, ее целях и задачах весьма схожа с тем, что наблюдается в такой области, как искусственный интеллект [42]. Существующие отечественные и зарубежные идеи для решения проблемы искусственного интеллекта [11], используемые в системах управления, можно разделить на два различных, хотя и связанных, направления.

Первое, более академическое направление - символизм [13], связано с когнитивистикой человеческого мышления и предполагает моделирование процессов функционирования, протекающих в мозгу человека. Здесь моделируются те или иные функции мозга (способы представления знаний, эвристическое программирование, экспертные системы и т.п.). При этом вопросы, связанные со структурами, порождающими эти процессы, не изучаются. В то же время в вычислительном плане данный подход для большинства реальных задач характеризуется большой трудоемкостью из-за возможного полного перебора вариантов во время поиска доказательства. Классический вариант данного подхода из-за возможного «комбинаторного взрыва» обеспечивает решение задач только при сравнительно небольшом размере базы данных и требует эффективной реализации вычислительного процесса [16].

Второе, сугубо прикладное и прагматическое направление - коннективизм, связано со стремлением получить интеллектуальную (когнитивную) сеть на нейроподобных элементах [9] (математическую модель), способную формировать эффективные управляющие решения в условиях нестационарной изменяющейся среды и априори неопределенных возмущающих воздействий.

В течение первых тридцати лет исследований искусственного интеллекта нейронные сети считались, в основном, бесперспективным направлением. С 1950-х до конца 1980-х доминировал символьный подход. Он предполагал, что работу систем обработки информации вроде человеческого мозга можно понять благодаря манипуляциям с символами, структурами и правилами обработки этих символов и структур. И только в 1986 году появилась серьёзная альтернатива символьному подходу - её авторы использовали термин «параллельная распределённая обработка» (Parallel Distributed Processing) [39], но сегодня чаще используется термин «коннективизм» или коннекционизм (англ. connectionism). Одна из наиболее известных техник моделирования коннективизма — искусственные нейронные сети (ИНС).

1. Приложение нейронных сетей для построения ИСУ

Основанную на сетях из нейроподобных элементов форму искусственного интеллекта называют нейроинтеллектом. Технические реализации моделей нейроинтеллекта называют нейрокомпьютерами (нейропроцессорами, нейрочипами, нейротехническими системами и пр.) Науку, изучающую свойства таких сетей, называют нейроматематикой.

Традиционная нейроматематика подходит к созданию нейросетей основываясь на принципе, который говорит о том, что чем сложнее задача, тем более крупные нейронные сети или их конгломераты нужно использовать. Однако это не всегда верно. Использование в качестве базового элемента современных искусственных нейросетей формального нейрона приводит к тому, что за счёт полной абстракции от сложного биологического нейрона возникают технические ограничения на возможности таких нейросетей. Но и использование бионического нейрона, сделанного максимально близко к биологическому, так же не представляется возможным ввиду его многоструктурной сложности. Таким об-

разом, возникает необходимость поиска универсальной нейробионической парадигмы, направленной на анализ механизмов, закономерностей и принципов, предназначенных для создания и работы новой базовой основы нейрокомпьютеров, сочетающей в себе простоту проектирования классических нейросетей и базовую сложность и многофункциональность бионических нейронов.

В середине прошлого столетия была разработана первая модель нейрона [40] как простейшего процессорного элемента, выполняющего вычисление переходной функции от скалярного произведения вектора входных сигналов и вектора весовых коэффициентов, предложена конструкция сети таких элементов для выполнения логических и арифметических операций и сделано основополагающее предположение о том, что такая сеть способна обучаться, распознавать образы, обобщать полученную информацию. Одной из первых таких реализаций был простейший перцептрон Фрэнка Розенблатта [46], предложенный им и исследованный в 1957-1959 гг. для распознавания зрительных образов. Позднее это направление развилось в теорию распознавания образов или «искусственные нейронные сети».

Наибольшее распространение для построения ИСУ получили свёрточные нейронные сети (СНС). СНС кардинально отличаются от других сетей. Они используются в основном для обработки изображений [48], иногда для аудио и других видов входных данных. Типичным способом применения является классификация изображений: если на вход подаётся изображение отвертки, сеть выдаст «отвертка», если картинка молотка - «молоток». Входные данные передаются через свёрточные слои, в которых не все узлы соединены между собой. Вместо этого каждый узел соединен только со своими ближайшими соседями. Эти слои имеют свойство сжиматься с глубиной, причём обычно они уменьшаются на какой-нибудь из делителей количества входных данных (например, 20 узлов в следующем слое превратятся в 10, в следующем - в 5), часто используются степени двойки. Кроме свёрточных слоев есть также так называемые слои объединения. Объединение — это способ уменьшить размерность получаемых данных, например, из квадрата 2x2 пикселей выбирается наиболее красный пиксель. На практике на выходе свёрточной сети пристыкуют полносвязный перцептрон для дальнейшей обработки данных [34].

СНС удалось весьма преуспеть в распознавании изображений, голоса [5], текста, в том числе и рукописного [10], а также побеждать в некоторых интеллектуальных играх, таких как шахматы и го. Этими успехами они обязаны применению больших вычислительных мощностей и наличием огромных, размеченных порой вручную баз обучающих данных [31]. Для создания таких огромных баз данных аннотированных изображений, например ImageNet [47], ученым всего мира и другим энтузиастам даже пришлось объединить свои усилия.

Параллельно наполнению вышеупомянутой базы аннотированных изображений ведётся проект ILSVRC (ImageNet Large Scale Visual Recognition Challenge - соревнования по распознаванию широкоформатных визуальных образов в ImageNet), в рамках которого различные команды ежегодно соревнуются в классификации и распознавания объектов и

сцен в базе данных ImageNet. Рассмотрим победителей последних лет на этих соревнованиях:

- AlexNet [31]. Это работа Алекса Крижевского, Ильи Суцкевера и Джеффа Хинтона, которая сыграла существенную роль в популяризации СНС в области компьютерного зрения. [Архитектура AlexNet](#) была представлена на [ImageNet ILSVRC Challenge в 2012 году](#) и обошла все работы конкурентов (16% ошибок против 26% у архитектуры, занявшей второе место).

- ZF Net [55]. А вот победителем ILSVRC 2013 стала свёрточная нейронная сеть Мэтью Зеллера и Роба Фергюса, которая известна как [ZF Net](#) (аббревиатура от Zeiler и Fergus). Данная архитектура была улучшенной версией AlexNet: здесь увеличили размеры средних свёрточных слоев и уменьшили шаг и размер фильтра на первом слое.

- GoogLeNet [52]. В 2014 году вышеупомянутый конкурс выиграла СНС разработки [Шегеди и других](#) — сотрудников корпорации Google. Основная заслуга данной архитектуры состоит в разработке и внедрении специального входного модуля (Inception Module).

- VGGNet [50]. Сразу за GoogLeNet на ILSVRC 2014 расположилась [сеть Карена Симоньяна и Эндрю Циссермана](#), которая наглядно продемонстрировала, что глубина сети является ключевым фактором для производительности. Их сеть содержит 16 свёрточных и полносвязных слоев и имеет чрезвычайно однородную архитектуру.

- ResNet [26]. [Остаточная сеть \(Residual Network\)](#), стала победителем ILSVRC 2015. Ключевые особенности — интенсивное использование [пакетной нормализации](#). В конце архитектуры отсутствуют полносвязные слои. ResNet по состоянию на сегодняшний день является настоящим произведением искусства в мире свёрточных нейронных сетей и используется наиболее часто.

Стоит также отметить, что, на международных соревнованиях по распознаванию образов, проводимых ImageNet, свёрточные нейронные сети всегда были в первых строчках рейтинга, то, что касается вопроса манипулирования предметами [8], то здесь нейронные сети ещё очень далеки от человеческого мастерства даже на таких базовых сенсомоторных навыках как схватывание и перемещение предметов, не говоря уже о владении более сложными орудиями труда [37].

В случае применения ИНС в составе ИСУ РТК [14] недостаточно просто распознать объект на изображении полученном с камеры, необходимо так же дополнить объект информацией о его местоположении и способе захвата. Если речь идет о манипуляторе, то типичный подход к робототехническому захвату и управлению движением [43] включает в себя:

- Методы компьютерного зрения для оценки положения объекта.
- Методы расчета конфигурации захвата цели.
- Алгоритмы планирования траектории движения.
- Алгоритмы, отслеживающие эту траекторию.

Важными показателями интеллектуального уровня системы управления РТК является уровень обобщения моделей внешней среды, на основании которых происходит оценка

конкретных ситуаций и прогнозирование их развития, а также возможности самоусовершенствования, в том числе при активном взаимодействии для этого с внешней средой.

В программном коде системы управления не представляется возможным предусмотреть все возможные ситуации, которые могут возникнуть при контакте РТК с реальностью, поэтому прибегают к использованию нейронных сетей и контролю обратной связи от системы технического зрения, что в совокупности служит для повышения качества выполнения следующих задач:

- обработка сенсорной информации и распознавание образов;
- прогнозирование на основе полученной от сенсоров информации, а также принятие решений по адекватному поведению и его планирование;
- управление движениями для реализации этих планов.

Соответственно, методы решения перечисленных выше задач сводятся к выполнению следующих этапов построения ИНС:

1. Выбор моделируемой зависимости (формализация задачи), определение входных и выходных данных.
2. Выбор структуры нейронной сети - определение числа входов, выходов, скрытых слоев, нейронов в каждом слое, функции активации, метода обучения.
3. Масштабирование переменных - определение диапазонов изменения входов и выходов в соответствии с уровнем функции активации.
4. Инициализация параметров сети - определение начальных значений весовых коэффициентов (обычно случайным образом), пороговых уровней.
5. Обучение нейросети - заключается в подстройке весовых коэффициентов.
6. Тестирование нейросети на ранее неизвестных данных.

Таким образом, можно заметить, что для построения ИСУ современных РТК используются математические модели ИНС, основным преимуществом которых является то, что они позволяют синтезировать закон управления с помощью одной лишь выборки обучающей информации. Соответственно применение нейросетевых технологий целесообразно при решении задач, имеющих следующие признаки [2]:

- отсутствие алгоритмов решения задач при наличии достаточно большого числа примеров;
- наличие большого объема входной информации, характеризующей исследуемую проблему;
- зашумленность, частичная противоречивость, неполнота или избыточность исходных данных.

2. Базовые технологии построения ИСУ на основе ИНС

Процесс управления роботом начинается с видеонаблюдения, то есть речь идет о видеоинформации, а это важнейшая сенсорная информация, как в животном мире, так и в технике в целом, включая, конечно, и робототехнику, поэтому для оцувствления РТК наи-

более широкое применение получили системы технического зрения (СТЗ), которые ориентированы, прежде всего, на обслуживание исполнительных систем.

В СТЗ, в общем случае, последовательно решаются следующие задачи обработки зрительной информации [18]:

- получение изображения;
- предварительная обработка изображения;
- сегментация изображения;
- определение характеристик образов;
- распознавание образов.

Все необходимые операции для задач построения СТЗ реализованы в библиотеке OpenCV (Open Source Computer Vision Library). OpenCV – одна из самых популярных библиотек компьютерного зрения. Она написана на C/C++, ее исходный код открыт. Библиотека включает более 1000 функций и алгоритмов.

Существуют, конечно, библиотеки, более продвинутые по функциональности, например, Halcon. Есть библиотеки более специализированные, делающие акцент на какой-либо конкретной задаче, например, libmv. Но OpenCV – самая большая библиотека по широте тематики.

Интересный альтернативный подход к локализации объектов на изображении, реализован в YOLO (You Only Look Once) [45]. Задача локализации формулируется как одноступенчатая задача регрессии: единственная нейронная сеть принимает на вход всё изображение целиком и выдаёт координаты ограничивающих прямоугольников и вероятности принадлежности классам для них. YOLO делит изображение на решётку. За обнаружение объекта ответственна та ячейка решётки, в которую попадает его центр. Каждая ячейка ищет ряд ограничивающих прямоугольников одного и того же класса. YOLO накладывает сильные ограничения на пространственное расположение объектов. Из-за своей решётчатой структуры система не справляется с поиском мелких объектов, расположенными плотными группами.

Для построения нейронных сетей можно использовать следующие популярные фреймворки и библиотеки:

- [TensorFlow](#) - открытый фреймворк Google для машинного обучения, на котором, например, работает Google Translate;
- [Theano](#) - популярный фреймворк для машинного обучения;
- [Caffe](#) - ещё один фреймворк;
- [Torch](#) - фреймворк для научных вычислений, использующий графические процессоры;
- [MXNET](#) - масштабируемая система для машинного обучения, созданная Amazon и несколькими университетами.
- [Keras](#) - высокоуровневая библиотека для работы с нейронными сетями, запускающаяся поверх TensorFlow или Theano;
- [Lasagne](#) - лёгкая библиотека для создания и обучения нейронных сетей.

Для построения систем управления движением могут быть использованы различные среды виртуализации, такие как *rViz* и *Gazebo*, фреймворки для планирования и управления движениями роботов такие как «*MoveIt!*», которые поставляются в составе метаоперационной системы ROS на базе ОС Ubuntu.

После того как объект был идентифицирован, обучение захвату производится по двум основным стратегиям – самостоятельное обучение нейронной сети хватать предметы методом проб и ошибок с накоплением базы удачных захватов для соответствующих объектов в базе предметов и обучение человеком-оператором.

3. Построение ИСУ на основе обучения ИНС методом проб и ошибок

Этот подход был заимствован из природы, ведь в отличие от роботов, люди и даже животные ориентируются в любой незнакомой ранее обстановке быстро, уверенно и часто с чрезвычайно небольшим предварительным планированием своих действий, полагаясь исключительно на высокоразвитые и интеллектуальные механизмы обратной связи, которые используют сенсорные сигналы для исправления ошибок поведения. Поэтому для того чтобы роботы надежно справлялись со сложными и непредсказуемыми ситуациями в реальном мире, возникла необходимость применять в них ИНС используя аналогичные механизмы обратной связи от внешних сенсоров, обрабатывая их в реальном времени

Сначала известный объект в сцене сегментируется и распознается, а полученные в прошлом данные об опытах с этим объектом извлекаются, и генерируется новая гипотеза захвата или выбирается среди уже проверенных. После выполнения выбранного захвата оценивается производительность и обновляется память прошлых опытов с объектом [27].

И хотя управление и контроль РТК с помощью обратной связи от СТЗ широко и давно изучались в робототехнике [19, 28, 53, 54], вопрос о том, как именно интерпретировать сенсорный сигнал, остается исключительно сложным, особенно для таких задач, как манипулирование предметами. Поэтому вместо того, чтобы подбирать правила поведения для робота заранее и часто вручную, разумнее запрограммировать робота для их самостоятельного приобретения с нуля, изучая обширный опыт в реальном мире во время наблюдений за своими собственными действиями [36].

Пример архитектуры СНС для захвата с обратной связью по видео представлен в работе [44]. Поскольку объект может восприниматься под разными углами, выходной слой модели был представлен как 18-битный двоичный классификатор. После получения сверточной нейронной сетью (СНС) участка изображения, она определяет возможность захвата объекта по центру участка для 18 возможных значений угла захвата ($0^\circ, 10^\circ, \dots, 170^\circ$). Для каждого участка изображения на выходе получается 18 значений, соответствующих 18 возможным углам захвата. Захват выполняется на участке изображения, которому соответствует максимальное значение на выходе СНС для координат и значений угла захвата.

Для обучения захвату методом проб и ошибок в работе [37] обучили большую сверточную нейронную сеть [35] предугадывать вероятность успешного захвата, используя только монокулярные изображения камеры, независимо от настройки камеры или текущего положения робота. Причем её обучали предугадывать вероятность успешного захвата, используя только лишь изображения с одной камеры, направленной в зону интереса. Независимо от настройки камеры или текущего положения робота, сеть могла наблюдать пространственную взаимосвязь между успешным захватом предмета и происходящим в сцене съёмки, тем самым обучаясь координировать действия манипулятора с изображением с камеры. Затем данная предобученная сеть продолжила обучение по захвату предметов в реальном времени и на реальном устройстве для достижения большего числа успешных попыток.

Для этого первоначальные попытки захвата выполняются роботом случайным образом и преуспевают крайне редко, но каждый успешный опыт захвата предмета используются для обучения глубокой сверточной нейронной сети, чтобы в дальнейшем научиться прогнозировать результат успешного захвата учитывая изображение с камеры и какие команды для двигателей этому способствовали. По сути, робот постоянно предсказывает, наблюдая за движением своей руки, какое последующее движение максимизирует его шансы на успех. Результатом является непрерывная обратная связь: что иначе можно назвать как координацией «рук и глаз». Робот наблюдает за своим захватом и исправляет свои движения в реальном времени. Он также демонстрирует интересное поведение до схватывания, например, выделение одного объекта из группы. Все эти поведения возникли, естественно, из обучения, а не запрограммированы в систему изначально.

Чтобы обучить СНС потребовалось более 800 тысяч попыток захвата в течение двух месяцев, с использованием от 6 до 14 манипуляторов, с различными положениями камеры и различиями в конструкции. Представленная сеть содержит три сверточных слоя, за которыми следует слой пространственной функции softmax (обобщение логистической функции для многомерного случая). В нем преобразуется пиксельная информация в численные значения, удобные для пространственных вычислений. Затем эта информация проходит ещё через три финальных полносвязных слоя для того чтобы синтезировать команды для двигателя. Таким образом вся сеть состоит из 7 слоев и имеет около 92000 параметров [36].

Метод достигает эффективного контроля в режиме реального времени, может успешно захватывать новые объекты и исправлять способ захвата путем дельнейшего нарабатывания опыта. Данный метод учит производить движения манипулятора в такие положения, которые наиболее вероятно произведут успешные попытки захвата, с подкреплением непосредственно из восприятия пикселей изображения с одной видеокamеры направленной в зону интереса, где происходят движение манипулятора в пространстве и находятся сами предметы для захвата. Постоянно пересматривая наиболее перспективные моторные команды, данный метод постоянно обрабатывает сенсорные сигналы из окружающей среды, что позволяет реагировать на внешние факторы воздействия и корректировать способ

захвата, чтобы максимизировать вероятность успеха. Кроме того, команды двигателя выдаются непосредственно в поле зрения робота, которому изначально не известно какой формы объект его там ожидает.

Это означает, что система в отличие от многих других аналогов не требует, чтобы камера была точно откалибрована относительно манипулятора, вместо этого она использует исключительно лишь одну видеокамеру для определения пространственной связи между манипулятором и объектами для захвата на сцене. Для этого были использованы два компонента: предиктор успеха захвата, который использует вышеупомянутую глубокую СНС, чтобы определить, насколько успешным может быть данное движение для захвата, и непрерывный механизм сервопривода, который использует СНС для постоянного обновления моторных команд робота. Благодаря непрерывному прогнозу наилучшего пути к успешному захвату механизм сервопривода обеспечивает робота быстрой обратной связью по отношению к движениям объекта, а также устойчивостью к неточному срабатыванию.

4. Построение ИСУ на основе обучения ИНС методом копирования действий оператора

В режиме копирования робот наблюдает за тем, как человек захватывает известный объект либо во время дистанционного управления с помощью задающих рукояток, либо при непосредственном захвате манипулятором робота. В этом эксперименте участие человека достаточно активно, он предоставляет роботизированной системе информацию о том, как нужно расположить запястье и пальцы роботизированного манипулятора для выполнения успешного захвата. Конечно, эта информация может быть передана роботизированной системе другим способом, например, через камеру или через взаимодействие в виртуальном представлении, эксперимент тогда станет более масштабируемым, так как он может быть проведен на компьютере, и достаточно будет просто кликнуть туда, где робот должен будет захватить объект вместо необходимости физического взаимодействия человека и манипулятора робота. Такой вариант обучения был ранее рассмотрен в статье [49]. Авторы в ней заявляют, что на момент публикации их робот являлся первым, который мог автоматически захватывать не виденные ранее объекты, расположенные случайным образом. Здесь параллельно выполняются два процесса распознавания – это распознавание объекта и распознавание конфигурации захвата. Затем модели объекта и захваты сохраняются вместе. Этот процесс может заменить или дополнить метод проб и ошибок, описанный выше, где РТК сам обучается хватать предметы.

В работе [38] авторы предложили метод глубокого обучения промышленного робота АВВ YuMi [24] при помощи манипуляторов Da Vinci [30] (2 высокоточных манипулятора с 6 степенями свободы) и системой стереозрения из двух камер Logitech C270, предоставляющих видео разрешения 640x480 и подключаемых по USB 2.0 соединению. Взаимодействие происходит посредством разработанного авторами интерфейса DY-Teleop и библиотеки с открытым кодом YuMiPy на языке Python.

Главные цели алгоритма взаимодействия DY-Teleop: позволить оператору быстро передавать двуручному роботу успешные демонстрации точных манипуляций и сохранять синхронизированную во времени информацию о траекториях движения, позиции манипуляторов робота, ширине раскрытия захвата, а также изображения рабочего пространства для глубокого изучения механизмов контроля роботом.

Вся система работает с задержкой в 194 миллисекунды и выполняет команды с частотой в 6 Гц, управление роботом происходит по протоколу Ethernet. Оператор управляет манипуляторами с 6 степенями свободы и захватами робота с помощью манипулятора Da Vinci Masters. Робот выполняет команды оператора и в то же время использует эти сведения для обучения.

Полностью архитектура системы включала:

- 3 компьютера под управлением Ubuntu,
- робот YuMi,
- две камеры Logitech C270,
- манипулятор Da Vinci Masters,
- 2 свитча TP-Link Gigabit Ethernet,
- фонарь Neewer CN-160 для освещения рабочего пространства робота.

Команды с манипулятора Да Винчи преобразуются в положения манипуляторов робота. Изображения со стереокамеры робота интегрированы в графический интерфейс пользователя и отображают настройки и информацию о системе на визуальном интерфейсе Да Винчи.

Нейронная сеть, которую использовали для обучения имела архитектуру предложенную [33] и реализованную на базе Tensorflow (открытая программная библиотека для машинного обучения, разработанная компанией Google для решения задач построения и тренировки нейронной сети с целью автоматического нахождения и классификации образов), состоящую из одного сверточного слоя и двух полносвязных слоев, с усеченным линейным преобразованием (ReLU). Коэффициенты сети вычислялись на графическом процессоре GeForce 980 GPU методом стохастического градиентного спуска. На вход нейронной сети подавались RGB изображения размерностью 100x250 пикселей, а для подаваемых изображений предварительно применялся алгоритм бинаризации для обеспечения устойчивости к изменениям освещения.

В качестве органов управления вовсе не обязательно использовать манипулятор (джойстик), в качестве сенсора движений вполне может выступать, например, костюм подобный «Xsens MVN», который генерирует данные в абсолютном трехмерном координатном пространстве. Если пользователь стоит в одинаковых позициях, но в разных местах, то выходные значения, выдаваемые костюмом, будут отличаться. Чтобы уменьшить поток данных и обеспечить стабильность использования дистанционной системы управления роботом, применяется предварительное преобразование данных от сенсоров разных конечностей относительно друг друга, аналогично пересчету углов их вращения [32].

В результате сбора данных получают взаимно соответствующие наборы команд для двигателей робота и набор углов между различными частями тела человека. На каждый двигатель робота используется отдельная нейронная сеть для обучения, в эксперименте каждая сеть содержала 1 скрытый слой из 20 нейронов. Каждая такая сеть обучалась аппроксимировать значение сигнала на двигателе исходя из относительного вращения соответствующих сенсоров на костюме для сбора данных. Функция пересчета представляет из себя матрицу значений, с весами в каждом узле. Эти веса оптимизированы на соответствие функции (обучение) как можно точнее с помощью метода роя частиц (метод численной оптимизации, для использования которого не требуется знать точного градиента оптимизируемой функции) [29]. За счет этого процесс обучения каждой сети проходил чрезвычайно быстро, в течение всего нескольких секунд на стандартном персональном компьютере. Каждое движение робота кодируется как соответствующая комбинация сигналов для двигателей робота. Полученные в ходе обучения веса нейронных сетей используются, чтобы контролировать робота в режиме реального времени. В ходе эксперимента были выполнены такие сложные движения как поднятие картонных коробок, удары по объектам, повтор боксирующих движений. Пользователь имел достаточный контроль для выполнения всех этих операций.

Рассмотренный в работе [51] метод может быть использован для роботов с любым количеством степеней свободы, авторы применили его для робота с 25 степенями свободы. Альтернативным подходом можно было бы назвать использование большего количества относительных вращений с датчиков для входа нейронных сетей, что позволило бы пользователю обучиться более сложным шаблонам контроля над роботом.

5. Проблемы нейросетевого подхода к построению ИСУ

Изначально критики выдвинули два [20] аргумента против того, что ИНС помогут нам лучше понять интеллект. Во-первых, ИНС с фиксированным размером входных данных, по-видимому, не способны решать проблемы с входными данными переменного размера. Во-вторых, ИНС вроде бы не способны привязывать значения к конкретному местонахождению в структурах данных. Способность записи и чтения из памяти является критически важными системами обработки информации.

Первый аргумент был опровергнут созданием рекуррентных ИНС (РНС). Они могут обрабатывать входные данные переменного размера без необходимости модификации или добавления компонента времени в процедуру обработки — при переводе предложения или распознавании голоса [21] и рукописного текста [4] РНС неоднократно получают входные данные фиксированного размера столько раз, сколько требуется.

Второй аргумент пытаются опровергнуть созданием нейронной машины Тьюринга (НМТ) [22], которая предоставляет ИНС доступ к внешней памяти и способность обучаться, как её использовать. В отличие от большинства моделей с рабочей памятью, данная архитектура может научиться использовать свою рабочую память вместо развертывания фиксированного набора процедур над символическими данными.

Нейробиологические модели рабочей памяти мозга и цифровая компьютерная архитектура предполагают, что функциональность системы может зависеть от наличия внешней памяти. Нейронные сети, дополненные внешней памятью, предлагают возможный ответ на ключевой критический аргумент в сторону коннекционизма, что нейронные сети не способны привязывать значения к конкретному местонахождению в структурах данных (связывание переменных).

Таким образом, НМТ напоминает рабочую систему памяти, поскольку она предназначена для решения задач, требующих аппроксимирования правил до «быстро создаваемых переменных». «Быстро создаваемые переменные» [25] - это данные, которые на короткое время привязаны к слотам памяти [41].

Так же исследователи [22] ставят вопрос о возможности нейронной сети выучить простейший алгоритм, демонстрируя входные данные и ожидаемый результат. Так, авторы обучают нейронную сеть справляться с задачей копирования последовательности данных. В этой задаче на вход сети подается последовательность элементов, на выходе от сети требуется воспроизвести эту последовательность. Эксперименты с данным алгоритмом демонстрируют, что НМТ обладает большей обобщающей способностью, чем обычные рекуррентные сети. Так, на этапе обучения использовались последовательности различной длины, однако все последовательности были короче 20 элементов. На этапе тестирования на вход сети подавались последовательности значительно большей длины, например, последовательности из 50 и 100 элементов. Для последовательностей малой длины и рекуррентная сеть, и НМТ демонстрируют практически идеальное качество, однако с увеличением длины последовательностей рекуррентная перестает работать корректно, тогда как НМТ продолжает копировать последовательности почти без ошибок. Помимо большей обобщающей способности НМТ обучается быстрее обычных рекуррентных сетей. При работе алгоритма хорошо видно, что работа с памятью нейронной машины Тьюринга похожа на то, что написал бы программист на языке низкого уровня, если бы перед ним стояла задача написать программу, копирующую последовательность элементов. Нейронная сеть выбирает ячейку памяти и начинает записывать элемент, после чего она переходит к следующей ячейке. На этапе воспроизведения последовательности нейронная сеть ставит головку чтения на первую запись последовательности, считывает ее и переставляет голову на следующую ячейку.

Предпосылкой для того, чтобы НМТ могла выучить действительно сложный алгоритм, такой как сортировка большого числа объектов, к сожалению, нет, что на самом деле вполне ожидаемо. Дело в том, что понять сложную зависимость исходя только из большого числа примеров входа и выхода алгоритма чрезвычайно сложно. В связи с этим НМТ может рассматриваться только как первый из множества шагов на пути исследователей к созданию машины, способной самостоятельно строить сложные алгоритмы.

Нейронные сети могут дать интересные результаты по генерации зависимостей и прогнозированию. Однако их очевидный недостаток – отсутствие явного алгоритма действия. Запоминание информации в процессе обучения происходит неявно в результате подбора

весовых коэффициентов нейронной сети, соответственно проблема познания (формирование новых знаний) на основе полученных ранее в процессе обучения знаний представляется трудно разрешимой. Положительное решение этой проблемы откроет путь к созданию полноценного искусственного разума [12].

Заключение

Построение ИСУ на основе обучения ИНС методом проб и ошибок требует огромных вычислительных ресурсов, больших баз данных обучающих наборов и временных затрат, и подойдет скорее для универсальных роботов, которым предстоит работать с огромным количеством разнообразных предметов, тем не менее, если планируется создание узкоспециализированных роботов существуют менее затратные методы построения ИСУ РТК, основанные, например, на копировании действий оператора.

Подход, основанный на копировании объекта и, одновременно, действий оператора имеет преимущества в случае, когда необходимо манипулировать небольшим числом предметов, тем более не нужно выделять отдельные временные ресурсы для обучения ИСУ РТК, оператору достаточно просто выполнять свою работу в обычном режиме, а ИСУ в это время как бы наблюдает со стороны через видеокамеру и учится, как правильно производить те или иные манипуляции с объектами. При этом принципиально важное значение приобретает возможность запоминать действия оператора и воспроизводить их с заданной степенью обобщения.

Перспективным с этой точки зрения представляется направление, где математическая модель ИНС строится на основе математической логики [6]. ИСУ роботом может быть реализована (построена) на основе математической модели когнитивного цифрового автомата (КЦА). ИСУ в данном случае представляет собой программно-аппаратный комплекс, где именно математическая модель КЦА определяет систему управления как интеллектуальную. Когнитивность математической модели определяется возможностью формирования (генерации) новых знаний на основе знаний, полученных на этапе обучения. Креативность математической модели определяется возможностью построения последовательностей (логических цепочек) формирования (генерации) новых знаний. Возможность когнитивного управления, в свою очередь, обеспечивает переход на качественно новый уровень управления сложными объектами.

В качестве исходной структурной схемы автомата служит описание структуры нейронной сети (НС), а в качестве модели нейрона используется логическая функция «НЕ-И-ИЛИ». При этом логика компонентов структурной схемы изначально не определена. В качестве инструмента построения математической модели КЦА предлагается математический аппарат сетей Петри (СП): маркированные графы, ингибиторные СП и СП с программируемой логикой (СППЛ).

Особенность предлагаемой математической модели когнитивного цифрового автомата заключается в том, что процедура обучения исходной структуры НС может выполняться на ограниченном количестве обучающих наборов в режиме копирования с заданной

степенью обобщения, что, в свою очередь, достигается в результате предобучения исходной структуры НС. Кроме того, показатель качества, обеспечивающий преимущества модели КЦА перед существующими аналогами – это полное отсутствие ошибок не только для априори определенных обучающих наборов данных, но и на множестве неопределенных наборов. Наличие ошибок свидетельствует о неисправности КЦА или недостаточной полноте формулы (сетового алгоритма) познания, которая формируется в процессе обучения. Формирование формулы реляционного исчисления (сетового алгоритма) выполняется на основе результатов синтеза (обучения). При этом возможность формирования формулы реляционного исчисления зависит от критической массы (качества) обучающих наборов и алгоритмов обучения, т.е. возможность познания, закладывается еще на этапе обучения. Особое преимущество математической модели КЦА заключается в обеспечении возможности дообучения и многофункционального обучения исходной структуры НС.

В качестве основного показателя качества, обеспечивающего преимущества модели КЦА, может служить время обучения исходной нейронной сети, что особенно актуально в случае применения копирующего способа управления РТК, т.к. запоминание действий оператора с заданной степенью обобщения должно выполняться (в идеале) с первой попытки.

Исследование выполнено при финансовой поддержке РФФИ и Правительства Ульяновской области в рамках научных проектов № 18-47-732015 р_мк и № 19-47-730016 р_а.

Список литературы

1. Бочаров В.Ж., Бурковский В.Л. *Управление робототехническим комплексом в экстремальных условиях функционирования на основе нечетких нейронных сетей* // Вестник Воронежского государственного технического университета. 2016, т. 12, № 6, с. 90–95.
2. Громов Ю.Ю. и др. *Интеллектуальные информационные системы и технологии*. Учебное пособие. Тамбов: Изд-во ФГБОУ ВПО «ТГТУ», 2013. с. 244.
3. Жданов А. *Автономный искусственный интеллект*. ЛитРес, 2014. 362 с.
4. Изотов П.Ю., Суханов С.В., Головашкин Д.Л. *Технология реализации нейросетевого алгоритма в среде CUDA на примере распознавания рукописных цифр* // Компьютерная оптика. 2010, т. 34, № 2, с. 243–251.
5. Кипяткова И.с., Карпов А.А. *Разновидности глубоких искусственных нейронных сетей для систем распознавания речи* // Труды СПИИРАН. 2016, т. 6, № 49, с. 80–103.
6. Кожевников В.В. *Концепция математического моделирования когнитивных цифровых автоматов* // Ученые записки УлГУ, Серия: Математика и информационные технологии. 2015, т. 1, № 7, с. 48–53.
7. Марр Д. *Зрение. Информационный подход к изучению представления и обработки зрительных образов*. М.: Радио и связь, 1987. 400 с.

8. Попов А.В., Юревич Е.И. *Позиционно-силовое управление манипуляторами: состояние и перспективы* // Мехатроника, автоматизация, управление. 2008, № 5, с. 55.
9. Рутковская Д., Пилиньский М., Рутковский Л. *Нейронные сети, генетические алгоритмы и нечеткие системы*. Пер. с польск. И. Д. Рудинского. М.: Горячая линия-Телеком, 2013. 384 с.
10. Солдатова О.П., Гаршин А.А. *Применение сверточной нейронной сети для распознавания рукописных цифр* // Компьютерная оптика. 2010, т. 34, № 2, с. 252–259.
11. Станкевич Смолин Д. *Введение в искусственный интеллект. Конспект лекций*. М.: Физматлит, 2007. 264 с.
12. Л.А., Юревич Е.И. *Искусственный интеллект и искусственный разум в робототехнике*. СПб.: Изд-во Политехнического ун-та, 2012. 167 с.
13. Тейз А., Грибомон П., Луи Ж. *Логический подход к искусственному интеллекту* / под ред. Г. Гаврилов. Мир, 1990. 430 с.
14. Тимофеев А.В. К.Т.М. *Нейросетевые методы логического описания и распознавания сложных образов* // Труды СПИИРАН. 2013, т. 4, № 4, с. 144–155.
15. Трофимов В., Кулаков С. *Интеллектуальные автоматизированные системы управления технологическими объектами*. Инфра-Инженерия, 2016. 232 с.
16. Чинакал В.О. *Интеллектуальные системы и технологии*. Учеб. пособие. М.: РУДН, 2008. с. 303.
17. Юревич Е. *Теория автоматического управления*. 4 изд. БХВ-Петербург, 2016. 560 с.
18. Юревич Е.И. *Сенсорные системы в робототехнике*. СПб.: Изд-во Политехн. ун-та, 2013. 100 с.
19. Espiau B., Chaumette F., Rives P. *A new approach to visual servoing in robotics* // IEEE Transactions on Robotics and Automation. 1992. Т. 8. № 3. с. 313–326.
20. Fodor J.A., Pylyshyn Z.W. *Connectionism and cognitive architecture: A critical analysis* // Cognition. 1988, v. 28. no 1–2, p. 3–71.
21. Graves A., Jaitly N. *Towards End-To-End Speech Recognition with Recurrent Neural Networks* // JMLR Workshop and Conference Proceedings. 2014, v. 32, no 1, p. 1764–1772.
22. Graves A., Wayne G., Danihelka I. *Neural Turing Machines* // Frontiers in Neurorobotics. 2014, v. 1, p. 1–26.
23. Gu S. и др. *Deep reinforcement learning for robotic manipulation with asynchronous off-policy updates* // 2017 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2017, p. 3389–3396.
24. Guo M. и др. *Design of parallel-jaw gripper tip surfaces for robust grasping* // Proceedings - IEEE International Conference on Robotics and Automation. 2017, p. 2831–2838.
25. Hadley R.F. *The Problem of Rapid Variable Creation* // Neural computation. 2008, v. 21, no 2, p. 510–532.
26. He K. и др. *Deep Residual Learning for Image Recognition* // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2016, p. 770–778.

27. Herzog A. и др. *Learning of grasp selection based on shape-templates* // Autonomous Robots. 2014, v. 36, no 1–2, p. 51–65.
28. Jagersand M., Fuentes O., Nelson R. *Experimental evaluation of uncalibrated visual servoing for precision manipulation* // Robotics and Automation, 1997. Proceedings., 1997 IEEE International Conference on. 1997, v. 4, p. 2874–2880.
29. Kennedy J., Eberhart R. *Particle swarm optimization* // Neural Networks, 1995. Proceedings., IEEE International Conference on. 1995, v. 4, p. 1942–1948.
30. Krishnan S. и др. *Transition state clustering: Unsupervised surgical trajectory segmentation for robot learning* // The International Journal of Robotics Research. 2017, v. 36, no 13–14, p. 1595–1618.
31. Krizhevsky A., Sutskever I., Hinton G.E. *ImageNet Classification with Deep Convolutional Neural Networks* // Advances in Neural Information Processing Systems 25. 2012, p. 1097–1105.
32. Kuipers J.B. *Quaternions and Rotation Sequences* // Geometry, Integrability and Quantization. 2000, p. 127–143.
33. Laskey M. и др. *Robot grasping in clutter: Using a hierarchy of supervisors for learning from demonstrations* // IEEE International Conference on Automation Science and Engineering. 2016, p. 827–834.
34. LeCun Y. и др. *Gradient-based learning applied to document recognition* // Proceedings of the IEEE. 1998, v. 86, no 11, p. 2278–2323.
35. LeCun Y., Bengio Y., Hinton G. *Deep learning* // Nature. 2015, v. 521, no 7553. p. 436–444.
36. Levine S. и др. *End-to-end training of deep visuomotor policies* // The Journal of Machine Learning Research. 2016a, v. 17, no 1, p. 1334–1373.
37. Levine S. и др. *Learning hand-eye coordination for robotic grasping with large-scale data collection* // International Symposium on Experimental Robotics. 2016b, p. 173–184.
38. Liang J. и др. *Using dVRK teleoperation to facilitate deep learning of automation tasks for an industrial robot* // 2017 13th IEEE Conference on Automation Science and Engineering (CASE). 2017, p. 1–8.
39. McClelland J., Rumelhart D. *Parallel distributed processing: Explorations in the microstructure cognition*. MIT Press Cambridge, 1986. 547 с.
40. McCulloch W.S., Pitts W. *A logical calculus of the ideas immanent in nervous activity* // The Bulletin of Mathematical Biophysics. 1943, v. 5, no 4, p. 115–133.
41. Minsky M.L. *Finite and Infinite Machines*. Prentice-Hall, Englewood Cliffs, N.J., 1967. xviii + 317 pp., illus. \$12. Prentice-Hall Series in Automatic Computation // Prentice-Hall Series in Automatic Computation. 1968, v. 159, no 3818, p. 966–967.
42. Ostroukh A.V. *Intelligent Systems*. Publishing House Science and Innovation Center, 2015. 110 с.

43. Pastor P. и др. *Online movement adaptation based on previous sensor experiences* // IEEE International Conference on Intelligent Robots and Systems. 2011, p. 365–371.
44. Pinto L., Gupta A. *Supersizing Self-supervision: Learning to Grasp from 50K Tries and 700 Robot Hours* // 2016 IEEE International Conference on Robotics and Automation (ICRA). 2015. v. 2016–June, p. 3406–3413.
45. Redmon J. и др. *You Only Look Once: Unified, Real-Time Object Detection* // Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment. 2015, v. 794, p. 185–192.
46. Rosenblatt F. *The perceptron: a probabilistic model for information storage and organization in the brain* // Psychological review. 1958, v. 65, no 6, p. 386–408.
47. Russakovsky O. и др. *ImageNet Large Scale Visual Recognition Challenge* // International Journal of Computer Vision. 2015, v. 115, no 3, p. 211–252.
48. Savchenko A. V. Maximum-likelihood dissimilarities in image recognition with deep neural networks // *Computer Optics*. 2017, v. 41, no 3, p. 422–430.
49. Saxena A., Driemeyer J., Ng A.Y. *Robotic Grasping of Novel Objects using Vision* // The International Journal of Robotics Research. 2008, v. 27, no 2, p. 157–173.
50. Simonyan K., Zisserman A. *Very Deep Convolutional Networks for Large-Scale Image Recognition* // International Conference on Learning Representations (ICRL). 2014, p. 1–14.
51. Stanton C., Bogdanovych A., Ratanasena E. *Teleoperation of a humanoid robot using full-body motion capture, example movements, and machine learning* // Australasian Conference on Robotics and Automation, ACRA. 2012. p. 3–5.
52. Szegedy C. и др. *Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning* // Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence (AAAI-17). 2017. p. 4278–4284.
53. Wilson W.J., Hulls C.C.W., Bell G.S. *Relative end-effector control using cartesian position based visual servoing* // IEEE Transactions on Robotics and Automation. 1996, v. 12, no 5, p. 684–696.
54. Yoshimi B.H., Allen P.K. *Active, uncalibrated visual servoing* // Proceedings of the 1994 IEEE International Conference on Robotics and Automation. 1994, p. 156–161.
55. Zeiler M.D. и др. *Deconvolutional networks* // Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. 2010, p. 2528–2535.