

Адаптивное управление технологическим циклом на основе моделей нейрорегуляторов

В.С. СМОРОДИН, В.А. ПРОХОРЕНКО, А.В. КЛИМЕНКО

Предложен метод построения модели нейроконтроллера для реализации управления при наличии внешних возмущений для нахождения оптимальной траектории на фазовой плоскости состояний системы для технологического цикла производственного процесса. Используется тип нейроконтроллера, основанный на рекуррентной архитектуре нейронной сети с длинными краткосрочными блоками памяти в качестве базы знаний о внешней среде, предыдущих состояниях контроллера и управляющих действиях.

Ключевые слова: управление, искусственный интеллект, цикл, нейронная сеть.

A method is proposed for constructing a neurocontroller model for implementing control in the presence of external disturbances to find the optimal trajectory on the phase plane of the system states for the technological cycle of the production process. A neurocontroller type is used, based on the recurrent neural network architecture with long short-term memory blocks as a knowledge base about the external environment, previous controller states and control actions.

Keywords: control, artificial intelligence, cycle, neural network.

Введение. В последнее время теория искусственного интеллекта широко применяется для решения задач классификации, кластеризации, прогнозирования, аппроксимации, сжатия данных и ряда других [1], [2], [3]. Однако последние исследования в этой области показывают, что применение искусственных нейронных сетей (ИНС), которые в настоящее время считаются одним из наиболее важных направлений исследований данной области, не ограничивается только перечисленными классами проблем. Исследователи и практики заинтересованы в решении проблем управления сложными процессами в областях деятельности, которые трудно формализовать [4], [5], [6].

Необходимо отметить, что, несмотря на высокий уровень сложности практических задач, которые могут быть решены с помощью методов искусственного интеллекта, ИНС являются довольно эффективным и удобным инструментом для поиска их решений на основе построения конечной совокупности математических моделей, которая рассматривается как единая модель исследуемого объекта как сложной технической системы [7]. По этой причине применение обучения нейронных сетей для анализа сложных технологических объектов обеспечивает важное преимущество перед традиционными методами исследования, включая имитационное моделирование [8], поскольку в процессе обучения нейронная сеть способна извлекать сложные зависимости между входными и выходными данными, а также предоставить необходимые обобщения.

При анализе работы сложных технических систем существующие методы анализа часто обеспечивают недостаточную эффективность, особенно в случаях моделирования проекта, когда структура таких объектов может изменяться в процессе их эволюции. Причина этого заключается в разнообразии и сложности практических задач, возникающих на этапе моделирования проекта, а также при оценке надежности и безопасности работы потенциально опасных технических систем.

Поэтому разработка нового подхода к анализу сложных систем на этапе автоматизации моделирования их проектов, который позволил бы учитывать изменения структурной связности системы управления при возникновении изменений структуры технологического цикла из-за отказов, является задачей большего значения.

Такой подход может быть разработан с использованием процедуры моделирования проекта исследуемого объекта, которая основана на адаптируемой структуре системы управления с использованием модели нейроконтроллера, которая учитывает все изменения в технологическом цикле производственной операции.

Известно, что основная задача эффективного управления технологическим циклом производства заключается в реализации последовательности универсальных управляющих воздействий, которые позволили бы оптимизировать выходные параметры технологической системы при возникновении возможных изменений в структуре технологического цикла. Такие изменения могут быть результатом наличия элементов потенциально опасного производства в рассматриваемой многокритериальной задаче управления.

Недавние исследования в этой области показывают, что качественный анализ работы систем управления требует учета большого количества факторов, которые претерпевают изменения в процессе эксплуатации исследуемого объекта. Этого можно достичь путем реализации алгоритмов адаптивного управления для изучаемых систем.

Последние тенденции использования некоторых общесистемных принципов и методов исследования в различных областях знаний, открытых семантических технологий для интеллектуальных систем, приводят к унификации системного подхода при рассмотрении конкретных научных и практических задач.

Такие тенденции позволяют надеяться на будущее создание необходимой базы знаний и программного обеспечения, способного к логическому выводу, как части рассматриваемой задачи, что позволит исследователю взаимодействовать с системами различной степени сложности, независимо от их физической природы или ограничения некоторых конкретных формализации.

Одной из важнейших задач в этой области является задача построения адаптивной системы управления технологическим циклом, которая способна обеспечить рациональную структуру контура управления в данный момент времени [4]. Последнее напрямую связано с реструктуризацией цикла в процессе его работы и построением алгоритмов адаптивного управления для оптимизации потребления ресурсов технологического цикла в реальном времени при наличии внешних управляющих воздействий.

Моделирование контроллера нейронной сети эффективно при наличии высококачественного контроллера управляемой системы [10]. В этом случае нейронная сеть действует как аппроксиматор ее функции и обучается имитировать влияние контроллера на управляемую систему. В некоторых ситуациях может быть так, что использование нейроконтроллера, сконструированного таким образом, является более практичным из-за общих свойств ИНС.

В данной работе приведены результаты в области исследований управляемых технологических систем, основанных на построении моделей ИНС для обеспечения эффективного управления технологическим циклом производства [9], [11]. Предлагается метод построения модели нейрорегулятора для управления технологическим циклом производства при наличии внешних возмущений.

Реализация управления для задачи поиска оптимальной траектории в произвольной области сложной структуры требует высококачественного контроллера, который способен адаптировать свои действия в соответствии с локальными данными окружающей среды, доступными в данный момент времени. Для успешной реализации стратегий поиска пути также необходимо хранить и учитывать данные, полученные контроллером в предыдущие моменты времени. Изучение применимости ИНС для решения задач этого класса является важным направлением исследований из-за преимуществ, которые имеют эти модели.

В данной статье предлагается метод построения модели нейрорегулятора для реализации управления при нахождении оптимальной траектории в случае динамически изменяющейся области произвольной конфигурации. Рекуррентная архитектура нейронной сети с LSTM-блоками, которая позволяет хранить информацию о состояниях системы в прошлые моменты времени, которые могут значительно отличаться от текущего момента времени [12], [13], используется в качестве математической модели.

Краткий аналитический обзор. ИНС оказались эффективным инструментом для решения ряда различных проблем из разных областей человеческой деятельности. Свойства ИНС заставили исследователей рассматривать их как подходящую модель для решения контрольных задач. Различные подходы были разработаны для реализации нейронных сетей в

задачах управления, и существует множество примеров успешных приложений [4], [5], [6]. Были также разработаны приложения в области управления и оптимизации производственного процесса, обычно с использованием нейронных сетей с прямой связью для решения конкретных задач, связанных с производственной операцией или ее аспектами.

Некоторые подходы адаптивного управления, основанные на моделировании нейронных сетей, были предложены для управления установкой и управления динамическими системами. Периодические исследования нейронных сетей показывают, что можно успешно применять такую архитектуру для задач, в которых происходят процессы, развивающиеся с течением времени. Рекуррентная архитектура нейронной сети способна отображать зависимости от времени, что позволяет решать различные реальные задачи [2], [3]. Тем не менее, имея интересные потенциальные возможности [2],[14], которые могут быть достигнуты с различными вариациями рекуррентной архитектуры [6], [15], [16], [17], [18], он также имеет известную проблему, когда задача требует принятия с учетом долгосрочных зависимостей [13]. Блоки LSTM допускают долгосрочное хранение данных [12] и могут применяться к задачам, где необходимо учитывать долговременные зависимости от времени [19], [20].

Формализация задачи. В рассматриваемой задаче нахождения траектории на фазовой плоскости состояний системы управляемый объект движется по двумерной области, которая разделена на непересекающиеся субрегионы (ячейки), которые могут быть проходимыми или непроходимыми. Клетки за пределами края считаются непроходимыми.

Проходимому субрегиону присваивается значение 0, а непроходимому субрегиону присваивается значение 1. В данном регионе назначается целевой субрегион. Гарантируется, что путь от начальной позиции контролируемого объекта к целевому субрегиону существует в регионе на любой стадии его эволюции. В каждый момент времени контроллер получает вектор из семи элементов: данные по четырем ячейкам, смежным с текущей позицией контролируемого объекта, расстоянием до целевого субрегиона и направлением к целевому субрегиону. Результатом, полученным нейрорегулятором в данный момент времени, является вектор из четырех элементов, который определяет направление следующего перемещения контролируемого объекта в области. Контролируемый объект продолжает двигаться, пока не будет достигнут целевой субрегион.

Архитектура нейроконтроллера. Набор специфических особенностей задач управления, которые требуют от контроллера принятия решения в рамках какой-либо долгосрочной стратегии в случае динамически изменяющейся среды и доступности локальных данных окружающей среды произвольного характера в данный момент времени, требует от контроллера иметь конкретную структуру. Структура контроллера, включающая модуль кодера для кодирования и предварительной обработки данных об окружающей среде, модуль памяти для долговременного хранения данных и модуль принятия решений, который определяет выходные сигналы контроллера в данный момент времени, предлагается. Предложенная общая схема контроллера показана на рисунке 1.




Рисунок 1 – Общая схема контроллера (f0__)

Это подразумевает с точки зрения архитектуры ИНС, что сеть будет иметь структурные элементы с функциями, которые можно интерпретировать как функции перечисленных модулей. Входные слои данной нейронной сети могут рассматриваться как модуль кодера, который предварительно обрабатывает и кодирует входные сигналы. Например, в случае, когда контроллер имеет изображение в качестве входных данных, последовательность сверточных и подвыборочных слоев, которая постепенно уменьшает размерность данных и преобразует их в вектор, может рассматриваться как модуль кодера. Подсеть, которая состоит из модулей LSTM, можно рассматривать как структурный элемент для долгосрочного хранения данных. Подсеть произвольной структуры, которая связана со структурными элементами для кодирования и хранения данных и включает в себя выходной уровень сети, который генерирует управляющие сигналы, может рассматриваться как модуль принятия решений.

В рамках описанного подхода в этой статье рассматривается нейроконтроллер с рекуррентной архитектурой, содержащей блоки LSTM. Рекуррентная архитектура с блоком LSTM включает в себя три полностью связанных слоя, состоящих из пяти, шестнадцати и четырех нейронов, соответственно. Блок LSTM имеет состояние размера 16 и связан со вторым уровнем нейронной сети через элементы временной задержки. Текущее состояние передается на вход третьего слоя. Существует также соединение обратной связи через элементы временной задержки между вторым уровнем и первым уровнем. Экспериментально была выбрана архитектура, которая будет иметь минимальное количество нейронов во всех слоях и сможет обучать и выполнять поиск пути на тестовом наборе. На рисунке 2 показана схема этой архитектуры.

Выбор рекуррентной архитектуры основан на необходимости учитывать временные зависимости в данных об окружающей среде, доступных для контроллера. Блоки LSTM обеспечивают долговременное хранение данных. В случае задачи поиска пути это необходимо для реализации стратегий поиска пути, растянутых на относительно длительные периоды времени, требуемые задачей.

Модель нейроконтроллера, среда обучения и тестирования, а также процесс генерации данных были реализованы на языке программирования Python с использованием механизма машинного обучения Tensorflow.




Рисунок 2 – Схема рекуррентной архитектуры нейронной сети с блоком LSTM

Генерация обучающей выборки. Для успешного обучения нейронной сети важно использовать большую выборку данных, которая адекватно отображает различные ситуации в реальном мире, с которыми нейронная сеть может столкнуться.

Нейроконтроллер, описанный в этой статье, используется для решения задачи поиска пути в сложной среде произвольной структуры, которая может динамически изменяться со временем. Поэтому примеры таких сред должны быть сгенерированы для обучения и тестирования. Для процедуры обучения были созданы 30×30 регионов со случайным размещением непроходимых субрегионов. Клеточный автомат оказался подходящей моделью, позволяющей осуществлять постепенную эволюцию структуры региона.

Параметрируя автоматы различными способами, можно добиться различных структурных изменений, которые со временем приведут к увеличению или уменьшению количества непроходимых клеток в регионе или имеют круговую природу. Развивающиеся регионы можно дополнительно рандомизировать, выбирая длительности периодов времени (этапов), в которые произойдет следующее изменение региона. 100000 последовательностей областей 30×30 клеток с непроходимыми участками, изменяющимися во времени, были сгенерированы для использования в процессе обучения и тестирования нейроконтроллера.

В данной статье для обучения нейроконтроллера использовалось контролируемое обучение. Рекуррентная нейронная сеть обучается на последовательности входных и выходных сигналов. Чтобы обучить нейрорегулятор для реализации стратегий поиска путей, последовательности должны быть значительной длины. Для тренировки использовались последовательности из 40 движений. Последовательность состоит из списка векторов локальных данных для текущей ячейки на пути (сетевые входы, включая данные о соседних ячейках, рассчитанное расстояние и направление до целевой ячейки) и списка соответствующих векторов требуемого перемещения для достижения следующей ячейки в пути (желаемые выходы сети).

Такие последовательности в рассматриваемой задаче могут быть получены путем генерации примерных путей в регионах. Для этого в каждом регионе исходная ячейка и целевая ячейка были выбраны случайным образом. Чтобы иметь возможность получить тренировочные последовательности требуемой длины 40 движений, было проверено, что на протяжении эволюции региона существовал путь между клетками, и что кратчайший путь между ними составлял не менее 40 движений. Описанная процедура отбора клеток повторялась несколько раз в каждой области. Иногда конфигурация региона и эволюция его структуры делали невозможным выбор подходящих клеток. 10 % регионов с подходящими клетками использовались для тестирования после завершения обучения.

Поиск по принципу «лучший вначале» использовался для генерации путей между выбранными парами ячеек в развивающихся регионах. Учитывая нестатическую природу областей и тот факт, что в каждый момент времени для нейрорегулятора доступны только локальные данные, пути были сгенерированы динамически. Путь был восстановлен, начиная с каждой точки, где изменение локальных данных было вызвано динамическими изменениями структуры региона. На основе длины путей, сгенерированных описанной процедурой, одна или несколько обучающих последовательностей были подготовлены на основе каждой из них. 60 000 тренировочных последовательностей из 40 движений были получены на основе сгенерированных путей и использованы для обучения.

Обучение нейроконтроллера. В процессе обучения обнаруживаются такие значения параметров сети (веса соединений и значения смещения нейронов), что сеть выдает желаемые выходы для заданных входов. Обучение можно рассматривать как задачу нелинейной оптимизации, заключающуюся в минимизации некоторой функции потерь, заданной в обучающем наборе по всем параметрам сети. В этой статье использовалось контролируемое обучение, что соответствует ситуации, когда доступен большой набор данных с примерами контрольных последовательностей.

Нейроконтроллер был обучен с использованием алгоритма оптимизации RMSProp, чтобы минимизировать функцию потерь. В качестве функции потерь использовалась функция кросс-энтропии. Обучающий набор примеров последовательностей был разделен на партии, и параметры нейронной сети (все веса и смещения нейронов) были скорректированы после представления партии из 50 последовательностей. На рисунке 3 показана минимизация функции потерь в течение первых 20 эпох обучения.




Рисунок 3 – Значения функции потерь за 20 эпох обучения нейрорегулятора

Тестирование обученного нейрорегулятора. После обучения нейрорегулятор смог успешно найти траекторию на фазовой плоскости состояний управляемой системы с динамически изменяющейся конфигурацией субрегиона разрешенных состояний.

10 % сгенерированных последовательностей областей были использованы для проведения тестирования и оценки производительности обученной нейронной сети. Тест считался успешным, если нейрорегулятор не выполнял никаких запрещенных действий (двигаясь по непроходимой клетке) и смог достичь клетки-мишени менее чем за 60 движений. Контроллер смог создать путь к целевому субрегиону за разумное время примерно в 70 % областей тестового набора.

Заключение. Теоретические результаты исследований, описанные в данной статье, служат основой для дальнейшей разработки новых эффективных методов анализа и синтеза оптимальной структуры технических систем с адаптивным управлением. Предложенный авторами подход применим в его рамках для решения целого ряда задач синтеза оптимальной структуры управления и синтеза сложных технологических систем. Результаты исследования могут быть использованы при разработке интеллектуальных систем поддержки принятия решений, предназначенных для соответствующих задач, автоматизации технологических процессов производства с помощью систем искусственного интеллекта, разработки и автоматизации процесса проектирования новых технологических объектов, а также оценки качества продукции, контроль технологического цикла в режиме реального времени.

В ходе данной работы был разработан и апробирован подход к применению нейроконтроллера для реализации адаптивного управления технологическим циклом. Эксперименты на моделях показали, что нейроконтроллер на основе рекуррентной нейронной сети с блоками LSTM может быть успешно использован для задач адаптивного управления. Блоки LSTM позволяют нейронной сети хранить информацию о состояниях системы из прошлых моментов времени, которые могут значительно отличаться от текущего момента времени, что позволяет нейронной сети изучать долгосрочные зависимости и воспроизводить длинные последовательности реакции на случайные возмущения и внешние воздействия. Возможность повышения эффективности существующей архитектуры за счет добавления дополнительных модулей памяти и обучения более длинным последовательностям данных зависит от конкретных параметров работы объекта моделирования.

Литература

1. LeCun, Y. Backpropagation applied to handwritten zip code recognition / Y. LeCun, B. Boser, J.S. Denker, D. Henderson, R.E. Howard, W. Hubbard, L.D. Jackel // *Neural Computation*. – 1998. – Vol. 1, № 4. – P. 541–551.
2. Multiple Object Recognition with Visual Attention [Electronic resource]. – Access mode : <https://arxiv.org/abs/1412.7755>. – Date of access :05.11.2018.
3. Karpathy Deep Visual-Semantic Alignments for Generating Image Descriptions // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. – 2017. Vol. 39, № 4. – P. 664–676.
4. Nouri, K. Adaptive control of a nonlinear DC motor drive using recurrent neural networks / K. Nouri, R. Dhaouadi // *Applied Soft Computing*. – 2008. – Vol. 8, № 1. – P. 371–382.
5. Mayer, H. A System for Robotic Heart Surgery that Learns to Tie Knots Using Recurrent Neural Networks / H. Mayer, F. Gomez, D. Wierstra, I. Nagy, A. Knoll, J. Schmidhuber // *IEEE/RSJ International Conference on Intelligent Robots and Systems*. – 2006. – Vol. 22, № 13. – P. 543–548.
6. Huh, D. Real-time motor control using recurrent neural networks / D. Huh, E. Todorov // *Proceedings of IEEE Symposium on Adaptive Dynamic Programming and Reinforcement Learning (IEEE ADPRL)*. – 2009. – P. 42–49.
7. Maximey, I.V. Problems of theory and practice of modeling complex systems / I.V. Maximey, O.M. Demidenko, V.S. Smorodin. – Gomel : F. Skorina State University, 2015. – 263 p.
8. Maximey, I.V. Development of simulation models of complex technical systems / I.V. Maximey, V.S. Smorodin, O.M. Demidenko. – Gomel : F. Skorina State University, 2014. – 298 p.
9. Smorodin, V.S. The use of intelligent technologies in optimizing the structure of controlled technological systems / V.S. Smorodin, V.A. Prokhorenko // *Reports of BSUIR*. – 2018. – Vol. 8, № 118. – P. 30–35.
10. Omidvar, O. *Neural Systems for Control* / O. Omidvar, D.L. Elliott. – New York : Academic Press, 1997.
11. Smorodin, V. Application of Neuro-Controller Models for Adaptive Control. / V. Smorodin, V. Prokhorenko // *Recent Developments in Data Science and Intelligent Analysis of Information. ICDSIAI 2018. Advances in Intelligent Systems and Computing*. – 2019. – Vol. 836. – P. 30–38.
12. Hochreiter, S. Long Short-Term Memory / S. Hochreiter, J. Schmidhuber // *Neural Computation*. – 1997. – Vol. 9, № 8. – P. 1735–1780.
13. Bengio, Y. Learning long-term dependencies with gradient descent is difficult / Y. Bengio, P. Simard, P. Frasconi // *IEEE Transactions on Neural Networks*. – 1994. – Vol. 5, № 2. – P. 157–166.
14. Siegelmann, H.T. Computation Beyond the Turing Limit / H.T. Siegelmann // *Science*. – 1995. – Vol. 268, № 5210. – P. 545–548.
15. Elman, J.L. Finding Structure in Time / J.L. Elman // *Cognitive Science*. – 1990. – Vol. 14, № 2. – P. 179–211.
16. Jordan, M.I. Serial Order: A Parallel Distributed Processing Approach. *Advances in Psychology* / M.I. Jordan // *Neural-Network Models of Cognition*. – 1997. – Vol. 121. – P. 471–495.
17. Goller, C. Learning task-dependent distributed structure-representations by backpropagation through structure / C. Goller, A. Kuchler // *IEEE International Conference on Neural Networks*. – 1996. – P. 347–352.
18. Neural Turing Machines [Electronic resource]. – Access mode : <https://arxiv.org/abs/1410.5401>. – Date of access :05.11.2018.
19. Malhotra, P. Long Short Term Memory Networks for Anomaly Detection in Time Series / P. Malhotra, L. Vig, G. Shroff, P. Agarwal // *ESANN 2015 proceedings, European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning*. – 2015. – P. 89–95.
20. Graves, A. Hinton Speech recognition with deep recurrent neural networks / A. Graves, G. Mohamed // *IEEE International Conference on Acoustics Speech and Signal Processing (ICASSP)*. – 2013. – P. 6645–6649.