

АДАПТИВНАЯ СИСТЕМА УПРАВЛЕНИЯ ТЕХНОЛОГИЧЕСКИМ ПРОЦЕССОМ ПРОИЗВОДСТВА

В.С. Смородин, В.А. Прохоренко

Гомельский государственный университет имени Франциска Скорины

ADAPTIVE CONTROL SYSTEM OF A TECHNOLOGICAL PRODUCTION PROCESS

V.S. Smorodin, V.A. Prokhorenko

Francisk Skorina Gomel State University

Изложены принципы построения адаптивной системы управления технологическим циклом производства при наличии внешних управляющих воздействий. Построение адаптивных обратных связей по управлению осуществляется на основе результатов обработки данных модели нейрорегулятора и имитационной модели в составе технических средств сопряжения с системой управления и информационной базой имитационной модели технологического цикла производства. Приведена формализация процесса адаптивного управления с использованием методов нейросетевого моделирования для поддержки принятия управляющих решений, описана модель нейрорегулятора, процедура ее обучения и тестирования.

Ключевые слова: адаптивное управление, технологический процесс производства, нейронная сеть, нейрорегулятор, фазовая плоскость состояний, оптимальная траектория.

The principles of construction of an adaptive control system are described for technological cycle of production with external control actions. Adaptive control feedback connections are created based on data processing for the neuroregulator model and the simulation model included in the technical means of coupling with the control system and the database for the simulation model of a technological cycle of production. Formalization of an adaptive control process that uses neural network based modeling for decision making processes is given. Neuroregulator models, their training and testing procedures are described.

Keywords: adaptive control, technological production process, neural network, neuroregulator, phase plane of states, optimal trajectory.

Введение

При осуществлении процессов управления технологическим циклом производства часто возникает потребность комплексного учета многообразия факторов воздействия на технологический процесс случайных сбоев используемого оборудования, а также воздействий внешней среды, включая и человеческий фактор. В этой связи является актуальной реализация адаптивного управления процессом производства (с обратными связями по управлению) в составе технических средств управления технологическим циклом и программного обеспечения адаптации процесса управления на случайные внешние возмущения в ходе его реализации.

Следует отметить, что используемые в настоящее время технические средства управления могут в полной мере не учитывать все многообразие существующих внешних воздействий, что определяет необходимость разработки комплекса методов адаптации управления существующими технологическими процессами производства (ТПП) с вероятностными характеристиками, учитывающими присутствие случайных возмущений в процессе их реализации, а также методики и технологии использования программного обеспечения, реализующего алгоритмы адаптации управления технологическим циклом производства.

Методы искусственного интеллекта и машинного обучения, в том числе искусственные нейронные сети, в настоящее время широко применяются для решения ряда важных практических задач, связанных с распознаванием образов, предсказанием временных рядов, аппроксимацией и анализом данных, а также при исследовании трудноформализуемого класса существующих сложных технических систем. К данному классу могут быть отнесены различные виды систем управления технологическим циклом производства [1], процесс функционирования которых можем сопровождаться существенными изменениями текущих параметров реализации технологического процесса, а также структуры технологического цикла.

При этом возникающие на практике требования по обеспечению на соответствующем уровне надежности и безопасности функционирования потенциально опасных промышленных объектов [2] приводят к необходимости разработки и реализации новых специфических подходов [3] для принятия обоснованных решений при построении обратной связи по управлению и адаптивной составляющей соответствующей системы управления на наличие реализовавшихся возмущений техногенного и антропогенного характера.

Такой подход может быть осуществлен посредством построения вспомогательных моделей искусственных нейронных сетей [3][4] (ИНС) для нахождения оптимального (адаптивного) управления, в составе конечной совокупности математических моделей, включая имитационные, реализующей единую модель объекта исследования, которая используется в качестве базовой для модели нейрорегулятора, осуществляющего адаптацию управления к внешним возмущениям в составе технических средств сопряжения главной модели с технологическим циклом производства.

Необходимо при этом подчеркнуть, что применение математических моделей нейрорегуляторов для адаптации управляющих воздействий на внешние возмущения техногенного и антропогенного характера имеет существенные преимущества перед традиционными методами коррекции управления, поскольку искусственная нейронная сеть способна построить новые функциональные зависимости между входными и выходными данными в процессе обучения с предоставлением необходимых обобщений.

Таким образом, предметом исследования в данной работе являются методы и алгоритмы адаптации управления вероятностными технологическими процессами, методики и технологии использования совокупности математических моделей объекта исследования при построении оптимальных обратных связей по управлению объектом исследования – адаптивные системы управления вероятностными технологическими процессами производства.

1 Формализация процесса адаптивного управления

В основу формализации структуры адаптивного управления технологическим циклом производства положены результаты исследований авторов в области анализа функционирования вероятностных технологических систем [1][3][4].

Под адаптивным управлением в данной работе понимается способность системы управления изменять свои параметры в зависимости от штатных управляющих воздействий контроллера системы и внешних возмущений [4]. Технологический цикл представляет собой множество определенных ресурсов, а также набор технологических операций, которые потребляют эти ресурсы в процессе своей реализации [1]. Допускается конкуренция технологических операций за требуемые ресурсы. Таким образом, в рамках принятой формализации технологический цикл рассматривается в качестве замкнутой системы, для анализа и изучения которой могут применяться нейросетевые технологии, основанные на построении математических моделей ИНС. Математическая модель строится в пространстве

состояний и включает в себя набор входных и выходных данных, а также переменных состояния конечного набора взаимосвязанных математических моделей компонентов управления [4].

Формализация процесса управления технологическим циклом производства с вероятностными характеристиками основана на использовании в структуре контура управления специальных сигналов и стандартных элементов, которые в дальнейшем участвуют в формировании регулирующих воздействий на используемое оборудование посредством их логической комбинации [2]. Динамика взаимодействия компонентов системы адаптивного управления и ее структура исследуются на основе совмещения имитационного моделирования технологического объекта в режиме реального времени с отображением функциональных особенностей основных компонентов системы. Подобное совмещение составляет основу технологического моделирования и обычно связано с моделированием квазипараллельных процессов.

Регулирование поведения ТПП реализуется путем эмуляции основных функций компонентов технологической системы на основе имитационной модели объекта исследования, построенной в рамках системы автоматизации имитационного моделирования агрегатного типа [3].

Адаптация управления технологическим циклом выполняется на основе осуществления функций контроля за выходом за пределы допустимых границ диапазона изменений компонентов $\{U_{jh}\}$ переменных вектора управления $\{U_h\}$. Возврат значений переменных управления в рамки допустимых интервалов выполняется посредством специальных средств корректировки на основе агрегатов-процедур управления $\{UPROC_{nl}\}$. Структура взаимосвязей адаптивной системы управления с компонентами имитационной модели вероятностного технологического процесса производства приведена на рисунке 1.1.

Система управления (СУ) на данном рисунке представлена имитатором управления, содержащим регистры состояний системы $\{Z_{jh}\}$ и регистры переменных управления $\{U_h\}$, через которые осуществляется взаимодействие с имитационной моделью технологического цикла.

В общем случае адаптивная система управления состоит из элементов, представляющих собой сложным образом организованную схему взаимодействия управляющих сигналов типа «И» и логических схем слежения типа «ИЛИ», которые вырабатывают соответствующие выходные сигналы после обработки поступивших входных сигналов. При этом информация о ситуациях, возникающих при выполнении любого элемента в системе управления, хранится в теле соответствующего инициированного сигнала. К такому относятся нормальное исполнение

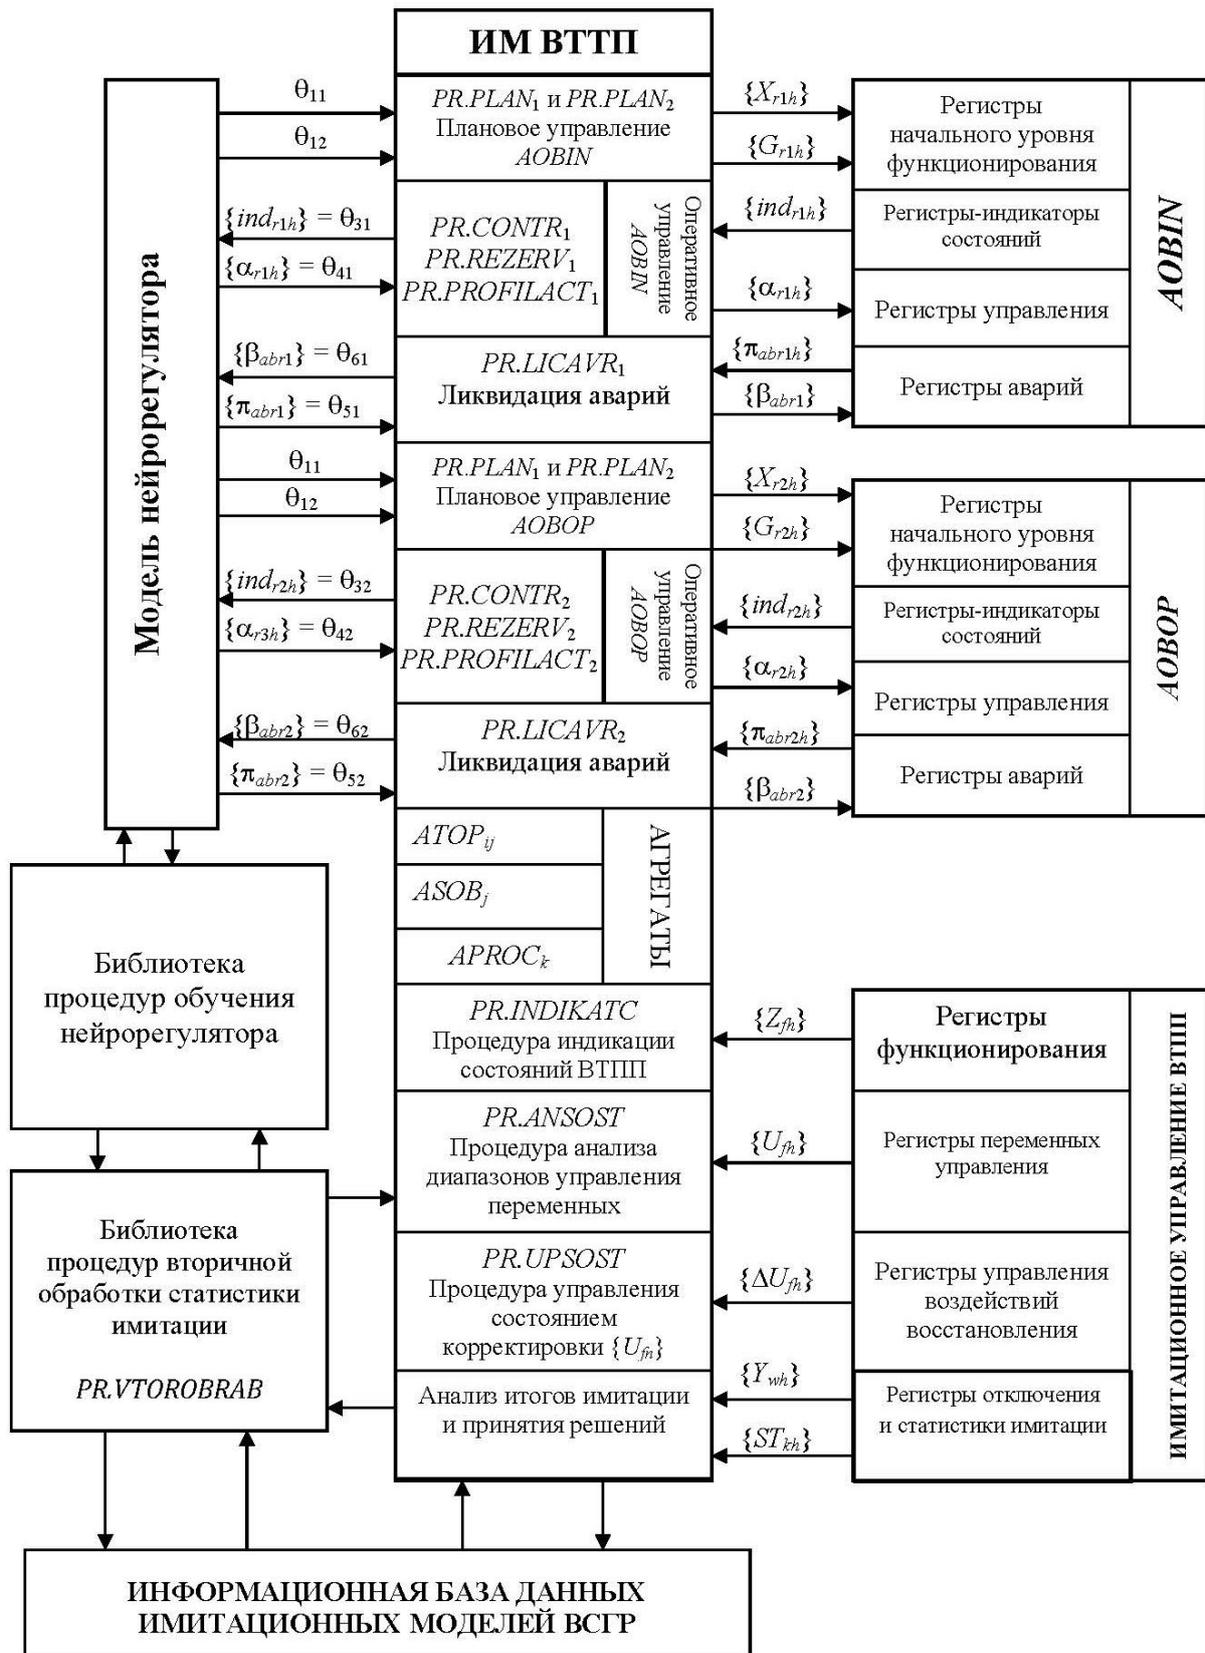


Рисунок 1.1 – Структура взаимосвязей адаптивной системы управления

функций элементом системы, отказ оборудования, выход параметров вектора $\{U_h\}$ за пределы допустимых изменений, совмещение отказов оборудования с выходом значений переменных правления за допустимые диапазоны.

Таким образом, сигнал, передаваемый от системы управления к оборудованию, может быть интерпретирован как набор признаков, описывающих оперативную ситуацию в ходе текущего выполнения некоторого элемента системы управления. В системе управления присутствует несколько типов устройств исполнения и адаптации: исполнители функций; устройства оперативной ликвидации последствий аварий оборудования; универсальные элементы, ликвидирующие последствия аварий и последствия выходов компонентов вектора $\{U_h\}$ за допустимые диапазоны изменений, в связи с чем имитационная модель системы управления генерируется из следующих типов исполнительных элементов: функция-исполнитель ($CORF_{ij}$) корректировки значений компонентов вектора управления U_k при выходе глобальных переменных за допустимые диапазоны изменений; функция-исполнитель ($LICV_{ij}$) ликвидации последствий аварии на оборудовании; универсальный исполнительный элемент ($UNIV_{ij}$), корректирующий значения компонентов вектора U_k и ликвидирующий последствия аварий на оборудовании; индикатор состояний ($INDS_{ij}$) технологического цикла [1][2].

2 Общая постановка задачи

В работе рассматривается управление технологическими процессами, имеющими непрерывную природу, в режиме реального времени [1] при наличии соответствующих технических средств автоматизации управления [4].

Процедура синтеза адаптивного управления основана на обучении рекуррентной нейронной сети [5], имеющей в своем составе блоки памяти LSTM [6]. Наличие структурных элементов, допускающих долговременное хранение информации [7], может интерпретироваться как нейросетевой аналог базы знаний о внешней среде системы управления. Выбор описанного метода адаптации удовлетворяет требованиям к быстродействию адаптации и качеству процесса управления в условиях возможного отсутствия информации о природе возможных случайных помех.

Модель нейрорегулятора, осуществляющая управление системой, предназначена для поиска оптимальной траектории на фазовой плоскости состояний системы управления [4]. В реальном времени модель принимает решения о переходе в новые состояния системы управления на фазовой плоскости. Решения принимаются с помощью

модели на основании данных о текущем состоянии объекта управления, а также соседних состояниях. Движение по фазовой плоскости состояний осуществляются до тех пор, пока не будет построена оптимальная траектория в рамках определенного критерия качества управления.

В рамках предлагаемой формализации могут быть использованы подходы с явным моделированием управляемой системы [8], подпадающие под категорию обучения с учителем. В этом случае модель нейрорегулятора обучается таким образом, чтобы она могла воспроизвести правильные последовательности стимулов и реакций. При решении реальных прикладных задач такие подходы могут быть сопряжены с трудностями построения достаточно полного и репрезентативного обучающего множества, отражающего весь спектр действий исходной модели. Даже несмотря на наличие больших наборов данных, содержащих статистики функционирования системы, покрытие важных областей фазового пространства состояний не гарантируется в случаях, когда они встречаются относительно редко, либо связаны с возникновением исключительных ситуаций, не наблюдаемых при нормальном функционировании системы [4].

Следует отметить, что в работе рассматривается альтернативный подход, связанный с использованием алгоритмов обучения с подкреплением (а именно, Q-обучения), применяемых совместно с имитационной моделью технологической системы. При использовании Q-обучения [9] предполагается исследовательская деятельность агента [8], управляемого контроллером, что позволяет пройти в процессе обучения через критические состояния системы. В процессе Q-обучения необходимо построить адекватную аппроксимацию функции Q оценки следующего состояния, к которому может привести выбор определенной политики управления. В качестве аппроксиматора данной функции может быть использована нейронная сеть [4], [10], [11]. Такой подход потенциально может обеспечить хорошие результаты при решении сложных задач с частично наблюдаемым окружением [11]–[13].

3 Модель нейроконтроллера, ее обучение и тестирование

Обучение нейроконтроллера представляет собой поиск таких значений весовых коэффициентов связей нейронной сети, при которых приближенная функция будет достаточно близкой к оптимальной функции Q* максимизации текущей возможной награды. Поиск в пространстве настраиваемых параметров модели осуществляется в результате многократного проигрывания эпизодов решения задачи, в которых участвует принимающий решения агент под управлением нейроконтроллера, при этом на основании различий, предсказанных нейрорегулятором, и

реальных значений награды за действия агента строится функция потерь, которая минимизируется градиентными методами [14], [15]. В описанной формализации эпизод решения задачи представляет собой поиск траектории агентом в двумерной области с возможным наличием непроходимых подобластей (недопустимых состояний системы).

Для обучения и тестирования моделей были сгенерированы экземпляры задачи нахождения траектории. Было сгенерировано несколько датасетов, характеризующихся объемом непроходимых подобластей, обозначенных как Empty (отсутствуют недопустимые состояния системы в области фазовой плоскости, где осуществляется поиск траектории), CA5 (5% недопустимых состояний), CA15 (15% недопустимых состояний), CA30 (30% недопустимых состояний).

В качестве оптимизационного алгоритма в данной работе использован RMSProp при обучении всех нейронных сетей. В качестве нейроконтроллера обучено и протестировано 3 нейронных сети. Первые две из них (sfDQN, mfDQN) являются многослойными перцептронами (МСП), третья – DQRN1 – рекуррентная на базе МСП с LSTM блоком [11]. Все функции активации для полносвязных скрытых слоев – SELU (Scaled Liner Exponential Unit) [16].

Агенты, использующие перечисленные нейроконтроллеры, после завершения обучения тестировались в течение 10000 эпизодов на экземплярах задачи, не использованных при обучении. Результаты обучения и тестирования в процессе обучения представлены ниже на рисунках 3.1–3.2. На всех рисунках красным показаны данные агента sfDQN, зеленым – mfDQN, синим – DQRN1. Первый график сверху – усредненная награда в процессе обучения, второй – количество достижений целевой области за последние 50 итераций (эпизодов), третий – среднее число достижений цели (в процентах) во время промежуточной валидации модели на небольшой

выборке данных (областей), не использованных в процессе обучения, (валидация осуществлялась каждые 1000 итераций обучения), четвертый – среднее число завершений эпизода совершением недопустимого действия (в процентах).

На датасете Empty – все агенты относительно быстро достигают высокой производительности (по сравнению с остальными датасетами), по результатам обучения все агенты способны успешно достигнуть целевой области в более чем 95% случаев.

На рисунке 3.1 (справа) видно, что применение моделей, учитывающих временные зависимости, фактически не даёт наблюдаемых преимуществ по сравнению с агентом под управлением sfDQN в ситуации, когда процент непроходимых областей относительно мал (CA5). Это может быть объяснено тем, что при решении экземпляра задачи, где непроходимые области изолированы и малы по объёму, вероятность их встречи агентом при осуществлении перемещений низкая, и от рекуррентной модели фактически не требуется учитывать временной контекст ситуации нахождения по соседству с непроходимой областью, и, следовательно, нужно меньше примеров для запоминания недопустимого действия.

Для датасета CA15 наблюдается другая ситуация: агент с рекуррентной нейросетью обучается быстрее и показывает себя незначительно лучше по результатам обучения (рисунок 3.2 слева).

При обучении на датасете CA30 DRQN также показывает себя лучше, при этом для сети такого типа необходимо обучение в течение более длительного периода. (Увеличение длительности обучения и подбор параметров для двух других моделей не позволяют в данном случае увеличить качество управления.) Например, по результатам тестирования обученных моделей на CA30 доля успешных построений траекторий для sfDQN, mfDQN, DRQN соответственно 35,12%, 34,67%, 56,28%.

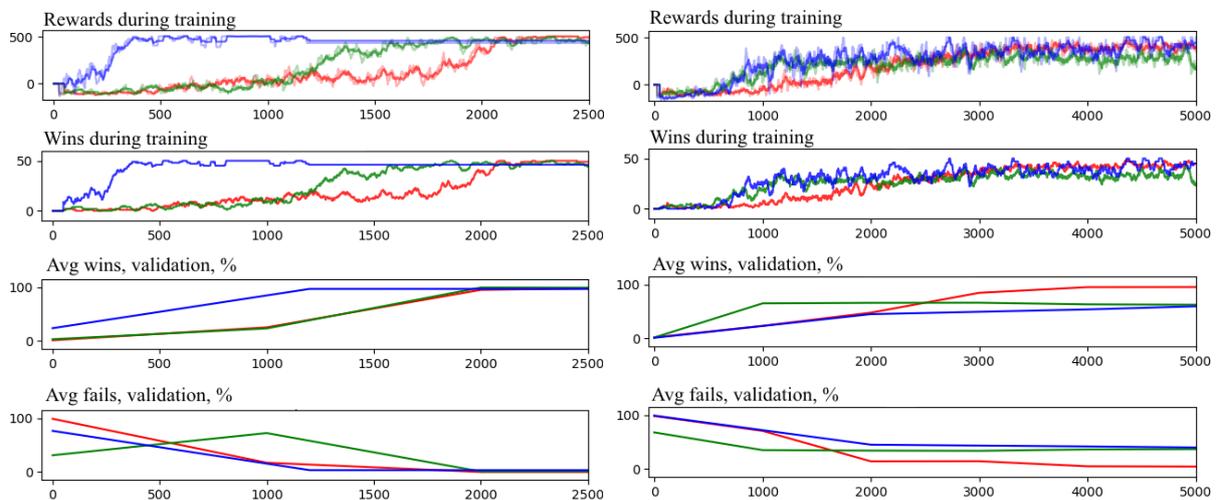


Рисунок 3.1 – Слева – обучение на датасете Empty, справа – на датасете CA5

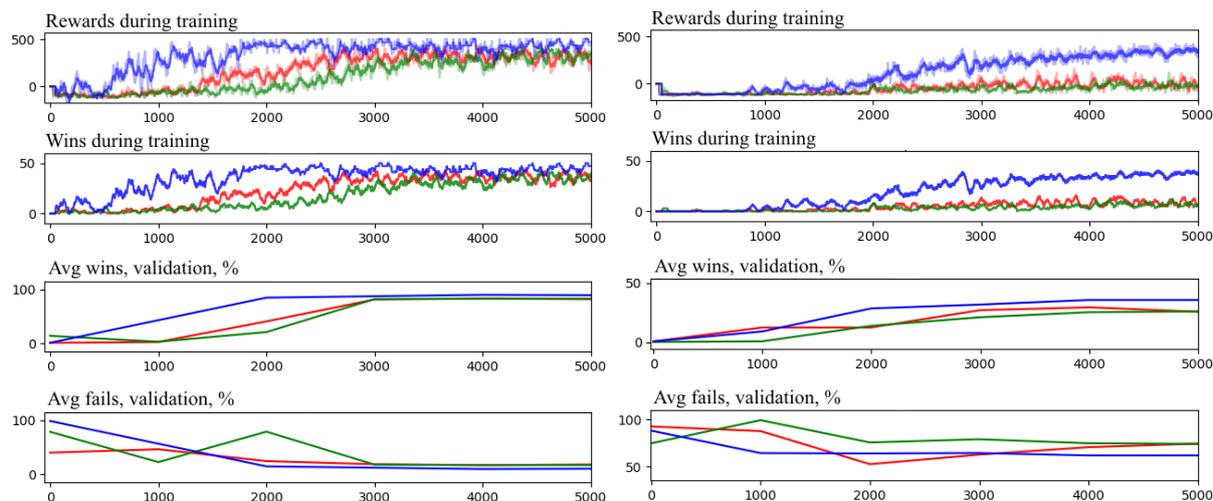


Рисунок 3.2 – Слева – обучение на датасете CA15, справа – на датасете CA30

Потенциально показанные результаты могут быть улучшены путем подбора архитектуры нейронных сетей.

Заключение

В настоящей работе предложен нейросетевой подход к построению адаптивной системы управления технологическим процессом производства с использованием нейрорегуляторов, применяемых для поиска оптимальной траектории на фазовой плоскости состояний технической системы. Математическая модель нейрорегулятора реализована программно на языке Python с использованием библиотек TensorFlow и keras.

Взаимодействие нейрорегулятора и системы управления технологическим циклом достигается за счет программно-аппаратного интерфейса между вычислительной системой и блоками управления АСУТП. Установлено, что рекуррентные нейронные сети могут быть успешно применены в качестве нейрорегулятора, осуществляющего решение задачи в описанной формализации в условиях, когда частично наблюдаемая область состояний системы имеет сложную структуру.

Представленные результаты обеспечивают возможность дальнейшей алгоритмизации адаптивного управления технологическим процессом производства на основе моделей нейрорегуляторов, позволяющих осуществлять контроль выхода параметров технологического цикла за пределы допустимых значений и построение обратных связей по управлению. Реализация алгоритмов адаптации управления на внешние возмущения дает возможность разработки схем структурного резервирования системы управления исследуемого объекта в условиях неопределенности и риска возникновения техногенных аварий в процессе производства.

Полученные результаты могут быть использованы в качестве составных компонентов при автоматизации технологических процессов и производств, разработке систем автоматизации проектирования, при реализации проектного моделирования новых роботизированных производств и систем управления, в учебном процессе для студентов, магистрантов и аспирантов.

ЛИТЕРАТУРА

1. Смородин, В.С. Система управления надежностью оборудования вероятностных технологических процессов опасного производства / В.С. Смородин // Проблемы програмування. – 2007. – № 3. – С. 107–123.
2. Гончаров, А.Н. Управление резервированием и восстановительными операциями с помощью имитационного моделирования при возникновении отказов в технологических процессах опасного производства / А.Н. Гончаров, И.В. Максимей, В.С. Смородин // Проблемы управления и информатики. – 2007. – № 1. – С. 48–60.
3. Смородин, В.С. Агрегатная система автоматизации моделирования вероятностных технологических процессов производства / В.С. Смородин // Математичні машини і системи. – 2007. – № 1. – С. 105–110.
4. Смородин, В.С. Метод построения модели нейрорегулятора при оптимизации структуры управления технологическим циклом / В.С. Смородин, В.А. Прохоренко // Доклады БГУИР. – 2019. – № 7–8 (126). – С. 125–132.
5. Осовский, С. Нейронные сети для обработки информации / С. Осовский. – Москва: Финансы и статистика, 2002. – 345 с.
6. Hochreiter, S. Schmidhuber, J. Long short-term memory / S. Hochreiter, J. Schmidhuber // Neural Computation. – 1997. – Vol. 9, № 8. – P. 1735–1780. – DOI:10.1162/neco.1997.9.8.1735.

7. *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.
8. *Hagan, M.T.* Neural networks for control / M.T. Hagan, H.B. Demuth // Proceedings of the American Control Conference. – San Diego, USA, 1999. – Vol. 3. – P. 1642–1656.
9. *Sutton, R.S.* Reinforcement Learning: An Introduction / R.S. Sutton, A.G. Barto. – Cambridge: The MIT Press, 1998.
10. *Tsitsiklis, J.* An analysis of temporal-difference learning with function approximation / J. Tsitsiklis, B.V. Roy // IEEE Transactions on Automatic Control. – 1997. – № 42. – P. 674–690.
11. *Cybenko, G.V.* Approximation by Superpositions of a Sigmoidal function / G.V. Cybenko // Mathematics of Control Signals and Systems. – 1989. – Vol. 2, № 4. – P. 303–314.
12. *Human-level control through deep reinforcement learning* / V. Mnih [et al.] // Nature. – 2015. – Vol. 518, № 7540. – P. 529–533. – DOI: 10.1038/nature14236.
13. *Lample, G.* Playing FPS Games with Deep Reinforcement Learning / G. Lample, D.S. Chaplot // AAAI'17 Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence. – 2017. – AAAI Press. – P. 2140–2146.
14. *Mastering the game of Go without human knowledge* / D. Silver [et al.] // Nature. – 2017. – Vol. 550. – P. 354–359. – DOI:10.1038/nature24270
15. *Hagan, M.T.* Neural Network Design / M.T. Hagan, H.B. Demuth, M.H. Beale. – Boston, MA: PWS Publishing, 1996.
16. *Klambauer, G.* Self-Normalizing Neural Networks / G. Klambauer, T. Unterthiner, S. Hochreiter // Advances in Neural Information Processing Systems. – 2017. – № 30. – P. 972–981.

Поступила в редакцию 15.03.2021.