

УДК 004.8.032.26; 57.007

Ляхов О. Л., Алёшин С. П., Бородина Е. А.

**НЕЙРОСЕТЕВАЯ МОДИФИКАЦИЯ ТЕКУЩЕГО ПРОСТРАНСТВА ПРИЗНАКОВ К ЦЕЛЕВОМУ МНОЖЕСТВУ КЛАССОВ**

При принятии решений в управлении объектами и процессами в различных трудно формализуемых областях деятельности (экономика, образование, медицина, экология, геология и т. д.) возникает проблема продуктивного анализа априорных данных. Отмеченные объекты относятся к классу сложных систем [1], эффективное управление которыми, было и остается актуальной проблемой, требующей своего решения. Особый интерес в этом контексте вызывают сложные социотехнические системы (ССТС), как обобщенное отображение современных производственных предприятий, медицинских учреждений, учебных заведений и т. д.

Современный алгоритмический и программный инструментарий, позволяет оперативно конструировать нейросетевую среду, реализовать широкий класс архитектур нейросетей различной сложности и правил модификации синаптического пространства [2]. Вместе с тем, применение технологии искусственного интеллекта (ИИ) в управлении ССТС раскрывает ряд нерешенных теоретических и практических проблем, одной из которых является проблема адаптации входного вектора факторов к целевому состоянию объекта. Это требует создания продуктивных СППР, методов, технологий и программного обеспечения построения моделей, позволяющих автоматизировать базовые процессы при распознавании состояний, прогнозировании динамики поведения и выборе оптимальных управляющих факторов исследуемых объектов на базе интеллектуальных технологий [3].

Разработкой, теоретическим обоснованием и внедрением информационных технологий на основе искусственного интеллекта для эффективного управления занимались отечественные и зарубежные ученые, в частности: Глушков В. М., Т. Кохонен, С. Хайкин, Р. Хехт-Нильсен и др. [4, 5, 6, 7]. Вопросами нейроуправления и оптимизации алгоритмов модификации синаптического пространства нейросетей при моделировании различных объектов и процессов занимались Галушкин А. И., Горбань А. Н., Миркес Е. М., и др. [8, 9, 10].

Вместе с тем, применение технологии ИИ в управлении ССТС раскрывает ряд нерешенных теоретических и практических проблем, одной из которых является адаптация входного вектора факторов к целевому состоянию объекта [3]. Это требует создания продуктивных СППР, методов, технологий и программного обеспечения построения моделей, позволяющих автоматизировать базовые процессы при распознавании состояний, прогнозировании динамики поведения и выборе оптимальных управляющих факторов исследуемых объектов на базе интеллектуальных технологий [2, 8, 10].

Целью данной статьи является представление разработанной технологии построения продуктивного ансамбля нейросетевых моделей нахождения такого набора входных факторов, который оптимально надежно и быстро позволяет привести ССТС в целевое состояние. В качестве инструмента моделирования был выбран нейроэмулятор среды StatSoft.

С точки зрения формализации процесса распознавания объекта необходимо построить отображение входного вектора данных на результат экспертизы, аппроксимирующее зависимость «поведение – вывод». В общем случае признаки поведения и число классов объектов являются векторными величинами:

$$| Y(t) | = F | X(t) |, \quad (1)$$

где  $Y(t)$  – номер класса состояния объекта;

$X(t)$  – вектор текущих значений входных признаков;

$F$  – функционал преобразования массива признаков в номер класса.

Задача адаптации входного вектора к требуемому состоянию ССТС состоит в нахождении оптимального набора входного вектора факторов  $X_0(t)$ , соответствующего вектору целевого состояния  $Y_0(t)$  объекта исследования.

Этот процесс может быть формально представлен последовательностью процедур:

$$F : X(t) \rightarrow Y(t) \Leftrightarrow Y_0(t) \rightarrow F_0 : Y_0(t) \rightarrow X_0(t), \quad (2)$$

где  $Y_0(t)$  – целевой вектор состояния объекта;

$X_0(t)$  – вектор адаптированных значений входных признаков;

$F_0$  – продуктивный функционал модификации массива текущих входных факторов к искомому набору, адекватному целевому состоянию.

Реализация алгоритма (2) позволяет найти оптимальный набор входных факторов как последовательное решение прямой и обратной задачи распознавания состояний ССТС. Решение обратной задачи в нейросетевом формате обеспечивает нахождение таких значений сигналов на входе обученной сети, при которых достигается выходное состояние, соответствующее нужному классу [3].

Адаптация входных факторов к целевым состояниям объекта.

Если актуальное состояние объекта не совпадает с требуемым, необходимо найти соответствующий набор входных факторов и привести его в это состояние. Для решения этой задачи следует найти функциональную зависимость состояний от входных факторов.

При этом минимизация целевой функции в постановке задачи выполняется итерационно в процессе обучения сети по алгоритму обратного распространения ошибки (или иным его модификациям) [5] применительно к входным данным исследуемого объекта:

$$\frac{1}{mn} \sum_{j=1}^n \sum_{i=1}^m (y_{ij} - d_{ij})^2 \Rightarrow \min(R \leq R_0), \quad (3)$$

где  $y_{ij}$  – вектор индикаторов выходных состояний;

$d_{ij}$  – результат обучения сети на  $j$ -м выходе, при  $i$ -м примере обучающей выборки;

$j = 1, n$  – номер выхода сети;  $i = 1, m$  – номер примера;

$m, n$  – размерность массива примеров и числа выходных элементов сети;

$R_0$  – допустимые ограничения по условию задачи.

В нейросетевом формате обучение заканчивается формированием ансамбля нейросетевых моделей. Анализ профилей результатов моделирования позволил выделить сети с приемлемыми для практики производительностью и ошибками на обучающих, контрольных и тестовых множествах. Установленная регрессионная зависимость определяет связь входных факторов и выходных индикаторов системы, через массивы синаптических коэффициентов обученных нейросетевых моделей. Вариации входными факторами позволяют получать различные значения функции, что обеспечивает системного менеджера данными для принятия решений. Однако, актуальное состояние объекта обычно не совпадает с требуемым. Тогда на основании гипотезы компактности не совпадают и признаковые пространства, соответствующие этим состояниям. Поэтому требуется такой набор признаков, который максимально сближал бы классы текущего и требуемого состояний ССТС. Это задача обратная распознаванию образов [3]. После формализации процедур оценки текущего состояния и функциональной зависимости «вход-выход», решалась задача формализации выбора оптимального признакового пространства в границах установленных дисциплинирующих условий. При небольшом числе изменяемых факторов (3–4) эта задача решалась простым перебором. В случае большого числа факторов (десятки – сотни) целесообразно воспользоваться одним из существующих градиентных методов адаптации входного вектора к заданной функции на выходе [5].

Задавались индикаторы, соответствующие требуемому классу состояния объекта, и подавались на вход обученной сети. Имея заданный ответ и ответ выданный сетью, вычислялся градиент функции ошибки по входным сигналам сети по известной технологии метода нагруженных двойственных сетей [9]. В соответствии со значениями элементов градиента изменялись значения входных сигналов сети в направлении снижения ошибки, что позволяет итерационно получить вектор входных сигналов, порождающих требуемый ответ. При этом синаптическая карта сети (на время адаптации) остается неизменной.

В первой фазе нейроэмулятор должен приобрести свойства инверсной динамики объекта, чтобы в первом приближении отображать динамику поведения объекта. Для этого вначале проводят обучение нейронной сети (нейроэмулятора) в автономном режиме при многократной коррекции синаптического пространства. В процессе обучения при необходимости применяется обогащение выборки, выбор наиболее информативных признаков (редукция), выбор оптимальной архитектуры и метода обучения. Как результат сеть выдает отклик требуемой точности или подлежит модификации (увеличивается число задержанных сигналов добавлением соответствующего числа входов сети). Окончанием процесса является достижение адекватности модели в заданных границах установленных показателей.

Для уменьшения риска переобучения нейроэмулятора коэффициенты скорости НЭ уменьшают несколько раз в сравнении с соответствующими коэффициентами для нейроконтроллера.

После достижения необходимой точности автономной реакции НК проводится дополнительное обучение обеих нейросетей на примерах управления ССТС при различных значениях уставки.

Вторая фаза обучения нейросетей системы нейроуправления проходит в рабочем режиме управляемого объекта. Главным является темп операций управления объектом, что обуславливает поступление реализаций  $Y(t)$ ,  $U(t)$   $Z(t)$ . Каждая новая реализация пополняет обучающую выборку для оперативного обучения.

Состояние  $O$  отслеживается контроллером, определяющим правильность его реакции на управляющие факторы, задавая управление  $Z$ .

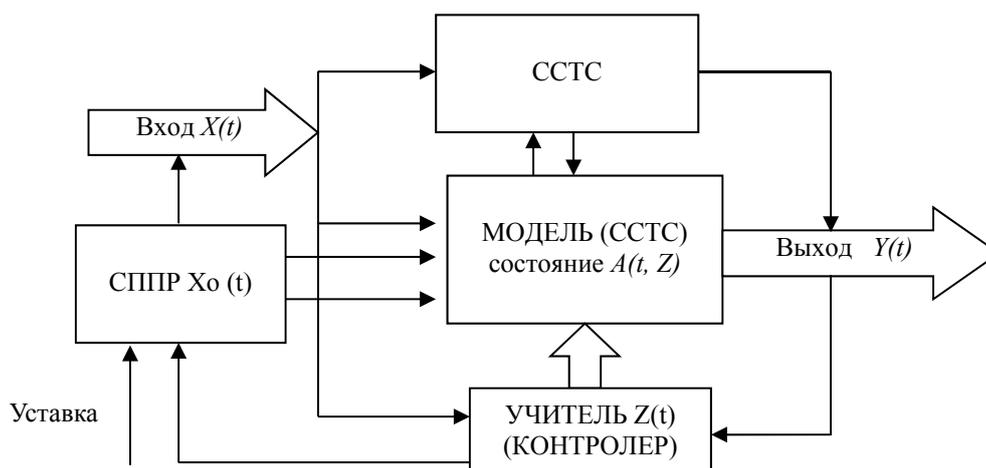


Рис. 1. Структура процесса адаптации входного вектора

В основе решения задачи лежит приведение ошибки обучения нейронной сети к входному слою нейронов и расчету частных производных градиента функции ошибки по параметрам нейросети и входным факторам. Градиентный спуск приводит к одному из возможных решений обратной задачи. Реализация осуществляется с применением построения нейросетевой модели и её обучение по методу нагруженной сети [9]. Метод позволяет вычислить производных выходной функции невязки текущего и требуемого состояний ССТС

по каждому элементу вектора входных факторов и запомнить их. При обратном функционировании эти ранее вычисленные производные участвуют для вычисления градиентов по входным сигналам сети [5].

Адаптивная система контроллера решает задачу сближения текущего значения выхода с требуемым, заданным вектором уставки. На рис. 2 представлена одна из схем нейроуправления объектом. Нейроэмулятор выполняет функции адаптивной модели управляемого объекта. На его входы поступают текущие и задержанные во времени значения векторов управления  $Z(t), Z(t - \theta), Z(t - 2\theta), \dots$  и значения разности между векторами входа и уставки  $Y(t) - U(t), Y(t - \theta) - U(t - \theta), \dots$ . Здесь  $\theta$  – величина шага задержки. Выходом нейроэмулятора является ожидаемое значение выхода управляемого объекта  $Y^*$ , а также значение вектора ошибки  $E$  для обучения нейроконтроллера.

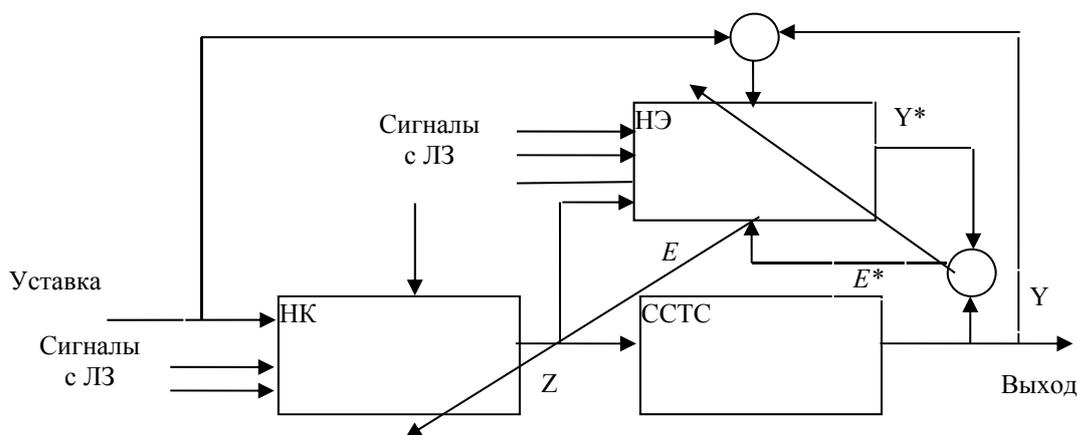


Рис. 2. Структурная схема адаптации входа нейроуправления объектом

Величина  $E^*(t) = Y(t) - Y^*(t)$  представляет вектор ошибки, который используется в алгоритме обучения нейроэмулятора. Ошибка, поступающая в схему контроллера, представляется как ошибка на выходе сети приведенная к первому слою в схеме нейроэмулятора [5, 10].

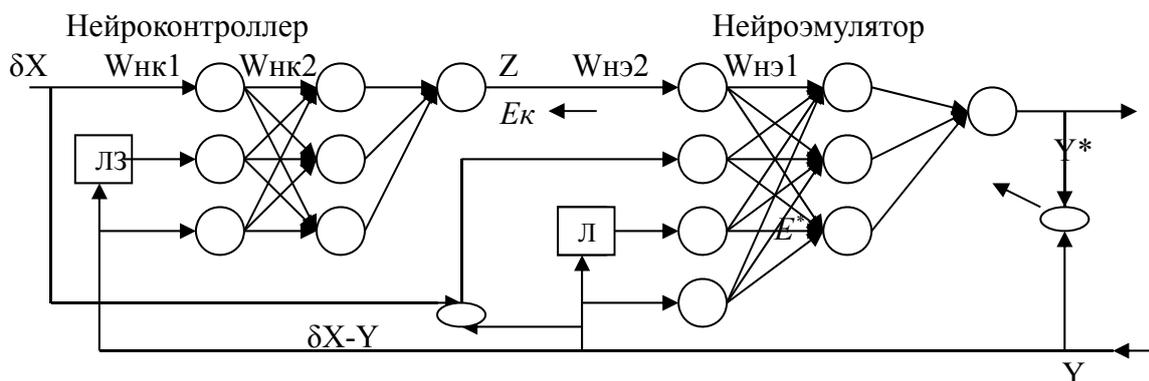


Рис. 3. Каскадная схема нейроуправления

На вход НЭ поступают:

- $Y(t)$  – текущие значения процесса на выходе;
- $Y(t - \theta)$  – текущие значения процесса задержанные на один такт  $\theta$ ;
- $U(t) - Y(t)$  – текущее значение невязки на выходе системы;
- $Z(t)$  – текущее управляющее воздействие.

Выходом нейроэмулятора являются значения выхода модели ССТС  $Y^*(t)$ .

При обучении НЭ осуществляется модификация синаптического пространства путем подстройки весовых коэффициентов в направлении антиградиента невязки:

$$w(t+1) = w(t) - \mu(\partial E / \partial w), \quad (4)$$

где  $\mu$  – коэффициент обучения;

$E$  – функция невязки (ошибка).

Обозначим ошибку НЭ как:

$$E^* = \frac{1}{2}(e^*)^2 = \frac{1}{2}(Y - Y^*)^2, \quad (5)$$

де  $Y$  – выход ССТС;

а  $Y^*$  – реакцию НЭ:

$$Y^* = f_{out}^e \left\{ \sum_{i=1}^{N_2} w_i^{e2} f^{e2} \left[ \sum_{j=1}^{N_1} w_{ij}^{e1} f^{e1}(y_j^{e1}) - b_i^{e2} \right] - b_{out}^e \right\}, \quad (6)$$

где  $f_{out}^e(\cdot), f^{e2}(\cdot), f^{e1}(\cdot)$  – сигнальные (активационные) функции нейронов 2-го та 1-го слоев;

$w_i^{e2}, w_{ij}^{e1}$  – весовые коэффициенты нейронов на участках между нейронами 2–3-го и 1–2-го слоев;

$b_{out}^e, b_i^{e2}$  – величины порогов нейронов выхода и скрытого слоя.

Для нейронов на входе используется линейная сигнальная функция, а для скрытого слоя – сигмоидная. Порог на выходе обычно равен нулю. Для оценки производной функции невязки выполнялись действия по известной методике [5, 9].

На выходе НЭ нейроэмулятора процесс формализуется выражением:

$$\partial E^* / \partial w_i^{e2} = -e^* f^{e2}(v_i - b_i^{e2}), \quad (7)$$

где  $v_i = \sum_{j=1}^{N_1} w_{ij}^{e1} y_j^{e1}$ .

Для связей между входами и скрытым слоем производная ошибки по весам имеет вид:

$$\partial E^* / \partial w_i^{e1} = -e^* \left\{ \sum_{i=1}^{N_2} w_i^{e2} \left[ \partial f^{e2}(v_i) / \partial v_i \right] \left[ \partial v_i / \partial w_{ij}^{e1} \right] \right\} = -e_i^{e1} y_j^{e1}, \quad (8)$$

где  $\partial v_i / \partial w_{ij}^{e1} = y_j^{e1}$ ;  $e_i^{e1} = e^* \sum_{i=1}^{N_2} w_i^{e2} \left[ \partial f^{e2}(v_i - b_i) / \partial v_i \right]$ . (9)

Величина  $e_j^{e1}$  представляется ошибкой, приведенной к  $j$ -му входу нейроэмулятора.

Для входа, на который поступает вектор управления  $Z$ , эта величина представляет ошибку реакции НК  $e^c$ , которая используется для коррекции синапсов НК. Подставляя полученные значения градиентов невязки в исходное выражение (3), получаем алгоритм модификации весовых коэффициентов НЭ:

$$w_i^{e2}(t+1) = w_i^{e2}(t) + \mu^{e2} e^* f^{e2}(v_i); \quad w_{ij}^{e1}(t+1) = w_{ij}^{e1}(t) + \mu^{e1} e_j^{e1}, \quad (10)$$

где величина  $e_j^{e1}$  рассчитывается по формуле (9). По такому же алгоритму осуществляется и подстройка весовых коэффициентов НК с учетом принятых обозначений входов и выходов.

Моделирование градиентного спуска с оценкой частных производных как по параметрам сети, так и по входным сигналам, представляющим пространство признаков текущего состояния объекта, показало устойчивую сходимость итерационного процесса обучения сети с приемлемыми показателями качества (рис. 4, 5).

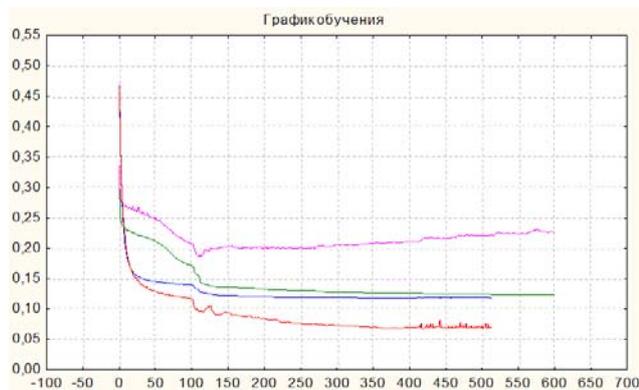


Рис. 4. Обучение моделей ВНС

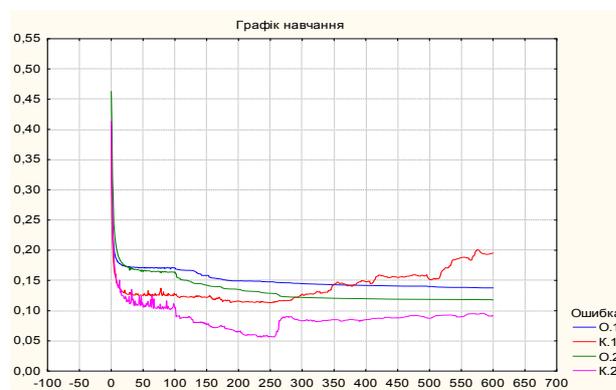


Рис. 5. Обучение моделей РБФ

## ВЫВОДЫ

Для автоматизации расчета факторов, приводящих актуальное состояние ССТС к целевому, необходимо найти функциональную зависимость её состояний от значений. Эта задача решена применением технологий нейруправления и реализована моделями многослойных персептронов как обратная задача распознавания.

Расчет частных производных по входным факторам выходной функции невязки текущего и требуемого состояний ССТС и обобщенная оценка градиента выполнены на основе известных свойств, двойственных нагруженных нейросетевых схем. Это позволило автоматизировать процесс определения элементов вектора градиента при реализации традиционного метода обратного распространении ошибки.

Практическая значимость результатов исследования состоит в создании алгоритмического и программного инструментария для перехода от автоматизированных к автоматическим системам адаптации пространства входных признаков к пространству требуемых классов в системах распознавания образов с высокой степенью априорной неопределенности.

## СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. Бусленко Н. П. Моделирование сложных систем / Н. П. Бусленко. – М. : Наука, 1978. – 400 с.
2. Боровиков В. П. STATISTICA NN : техническое описание / В. П. Боровиков. – М. : Мир, 1999. – 239 с.
3. Состояние и перспективы нейросетевого моделирования СППР в сложных социотехнических системах / А. А. Морозов, В. П. Клименко, А. Л. Ляхов, С. П. Алёшин // Математичні машини і системи. – 2010. – № 1. – С. 127–149.
4. Кохонен Т. Ассоциативная память / Т. Кохонен. – М. : Мир, 1980. – 384 с.
5. Хайкин С. Нейронные сети: полный курс : пер. с англ / С. Хайкин. – [2-е изд.]. – М. : Издательский дом «Вильямс», 2006. – 1104 с.
6. Хехт-Нильсен Р. Нейрокомпьютинг: история, состояние, перспективы / Р. Хехт-Нильсен // Открытые системы. – 1998. – № 4. – С. 10–14.
7. Глушков В. М. Кибернетика, вычислительная техника, информатика. В 3 т. Т. 2. ЭВМ – техническая база кибернетики / В. М. Глушков. – Киев : Наукова думка, 1990. – С. 140–177.
8. Галушкин А. И. Нейрокомпьютеры и их применение на рубеже тысячелетий в Китае / А. И. Галушкин. – М., 2004. – Т. 1. – 367 с.; Т. 2. – 464 с.
9. Горбань А. Н. Нейронные сети на персональном компьютере / А. Н. Горбань, Д. А. Россиев // Новосибирск : Наука, 1996. – 276 с.
10. Миркес Е. М. Нейрокомпьютер. Проект стандарта / Е. М. Миркес. – Новосибирск : Наука, Сибирская издательская фирма РАН, 1998. – 337 с.