

ко, практически не учитывают фрактальных особенностей строения моделируемых объектов. Попытка построения стохастических имитационных моделей образования тонкопленочных покрытий, основанная на генерации случайных процессов формирования потока частиц материала, их переноса к подложке и последующей адсорбции позволяет, в простейшем случае, получить лишь объекты, близкие к гауссовым (броуновским) поверхностям [8].

Очевидно, что негауссовы поверхности можно строить лишь при учете в моделях термодинамических особенностей зародышеобразования, сложных процессов кластеризации частиц, образования и коалесценции зародышей, перекристаллизации и т.п. Предлагаются, например, различные подходы к моделированию механизмов кластеризации и роста кристаллитов [10,11], или к моделированию процессов диффузии в виде процесса перколяции (протекания) в кристаллических решетках [1,12]. В целом, однако, это направление нельзя считать разработанным хотя бы в удовлетворительной степени, что представляет широкий простор для дальнейших исследований. Практически полезным результатом исследований в этом направлении должны явиться не только методы и средства моделирования процессов формирования микроструктур (в том числе – пленочных), но и выявленные закономерности, связывающие геометрические особенности структур (в том числе – фрактальную размерность), с одной стороны, с технологическими параметрами отдельных процессов, с другой – с достигаемыми электрофизическими характеристиками.

ВЫВОДЫ

При выполнении экспериментальных и теоретических исследований твердотельных тонкопленочных структур целесообразно привлечение фрактальных подходов, что может повысить адекватность описания параметров строения и связывания их с электрофизическими свойствами изучаемых объектов.

Некоторые известные экспериментальные методы исследования структурно-морфологических характеристик твердотельных объектов вполне применимы и для изучения их фрактальных свойств. Для повышения надежности получаемых результатов необходимо выполнить соответствующую адаптацию этих методов, а также разработать оригинальные специализированные методики измерений.

Необходима разработка новых, эффективных в вычислительном отношении методов и алгоритмов определения фрактальных размерностей поверхностей: алгоритмов, использующих различные двумерные частотные преобразования, а также методов определения размерности по косым и сферическим шлифам микроструктур. Для проверки и сравнительной оценки этих методов полезно использовать модельные поверхности с требуемыми фрактальными свойствами, сгенерированные известными способами.

УДК 681.324

Головко Вл.А., Головко Вал.А.

ПАРАДИГМЫ ОБУЧЕНИЯ НЕЙРОННЫХ СЕТЕЙ

Введение

Проблема создания искусственных систем, способных к обучению, самоорганизации и адаптации не является новой. Ее пытались решить еще на начальном этапе становления вычислительной техники [1,2]. В данных работах исследовались в

Наиболее обширной областью перспективных исследований является разработка методов и средств моделирования различных физических процессов, происходящих при формировании и модификации пленочных микроструктур и существенно влияющих на их структурные и электрофизические характеристики. В первую очередь, речь идет о процессах кластеризации частиц в переносимых потоках вещества, их адсорбции и миграции на подложке, зародышеобразования, роста и коалесценции зародышей, перекристаллизации пленок в результате термообработок и межфазных реакций. Представляется, что привлечение фрактальных подходов к рассмотрению упомянутых процессов существенно повысит адекватность моделирования тонкопленочных структур.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Федер Е. Фракталы. – М.: Мир, 1991. – 262 с.
2. Иванова В.С., Баланкин А.С., Бунин И.Ж., Оксогоев А.А. Синергетика и фракталы в материаловедении. – М.: Наука, 1994. – 384 с.
3. Дереченник С.С., Мороз О.В. Стохастическое моделирование процесса формирования тонкопленочных структур металл-кремний // Вестник БГТУ: Серия «Машиностроение, автоматизация, ЭВМ». – 2001, № 4(10). – С. 68-72.
4. Броудай И., Мерей Дж. Физические основы микротехнологии. – М.: Мир, 1985. – 496 с.
5. Аппаратные средства контроля параметров твердотельных структур в производстве СБИС / В.А. Емельянов, В.В. Баранов, Т.В. Петлицкая и др.; Под ред. А.П. Достанко. – Мн.: НПО «Интеграл», 1997. – 71 с.
6. Дереченник В.С., Дереченник С.С. Оценка фрактальной размерности поверхностей по их цифровым топографическим образам // Известия Белорусской инженерной академии. – 2002, № 1(13)/2. – С. 42-45.
7. Мандельброт Б. Фрактальная геометрия природы. – М.: Институт компьютерных исследований, 2002. – 656 с.
8. Дереченник С.С., Мороз О.В., Дереченник В.С. Стохастическое трехмерное моделирование микрорельефа тонкопленочных покрытий в металл-кремниевых структурах / Проблемы проектирования и производства радиоэлектронных средств: Материалы II Международной НТК (15-17 Мая 2002, Новополоцк). – Новополоцк: ПГУ, 2002. – Т. II. – С. 249-252.
9. Плазменные процессы в производстве изделий электронной техники. В 3-х т. Том 1 / А.П. Достанко, С.П. Кундас, М.Н. Босьяков и др.; Под общ. ред. А.П. Достанко. – Мн.: ФУАинформ, 2000. – 424 с.
10. Vicsek T. Fractal Growth Phenomena. – N.Y.: World Scientific Pub. Co, 1992. – 488 p.
11. Gaylord R.J., Tyndall W. Diffusion-Limited Aggregation // Mathematica in Education. – 1992, Vol.1. – P. 6-10.
12. Эфрос А.Л. Физика и геометрия беспорядка. – М.: Наука, 1982. – 264 с.

Головко Владимир Адамович, д.т.н., профессор, зав. каф. интеллектуальных информационных технологий Брестского государственного технического университета

Беларусь, БГТУ, 224017, г. Брест, ул. Московская, 267.

Головко Валерий Адамович, к.п.н., доцент каф. германской филологии Вильнюсского университета.

новый импульс в развитии нейронных сетей.

В настоящее время рынок продуктов в области нейроинтеллекта стремительно растет. Разработано большое число нейросетевых моделей, применяемых в различных областях: прогнозирование, управление, диагностика в медицине и технике, распознавание образов и т.д. Большое значение при этом имеет разработка эффективных алгоритмов обучения нейронных сетей. В общем случае существуют следующие методы обучения: обучение с учителем, подкрепляющее обучение и обучение без учителя. В данной статье проводится анализ основных концепций обучения нейронных сетей.

1. Обучение с учителем

При обучении с учителем используется *алгоритм обратного распространения ошибки*, который был предложен в [4] и является эффективным средством для обучения многослойных нейронных сетей. Рассмотрим нейронную сеть, состоящую из четырех слоев. Обозначим слои нейронных элементов от входа к выходу соответственно через k, i, j .

Тогда выходное значение j -го нейрона последнего слоя

$$y_j = F(S_j), S_j = \sum_i \omega_{ij} y_i - T_j, \quad (1)$$

где S_j – взвешенная сумма j -го нейрона выходного слоя; y_i – выходное значение i -го нейрона предпоследнего слоя; ω_{ij} и T_j – соответственно i -й весовой коэффициент и порог j -го нейрона выходного слоя.

Аналогичным образом выходное значение i -го нейрона предпоследнего слоя определяется, как

$$y_i = F(S_i), S_i = \sum_k \omega_{ki} x_k - T_i. \quad (2)$$

Алгоритм обратного распространения ошибки минимизирует квадратичную ошибку нейронной сети. Для этого с целью настройки синаптических связей используется метод градиентного спуска в пространстве весовых коэффициентов и порогов нейронной сети. Согласно методу градиентного спуска изменение весовых коэффициентов и порогов нейронной сети происходит по следующему правилу:

$$\omega_{ij}(t+1) = \omega_{ij}(t) - \alpha \frac{\partial E}{\partial \omega_{ij}(t)}, \quad (3)$$

$$T_j(t+1) = T_j(t) - \alpha \frac{\partial E}{\partial T_j(t)}, \quad (4)$$

где E – квадратичная ошибка нейронной сети для одного образа.

Она определяется, как

$$E = \frac{1}{2} \sum_j (y_j - t_j)^2, \quad (5)$$

где t_j – эталонное выходное значение j -го нейрона.

Ошибка j -го нейрона выходного слоя равняется

$$\gamma_j = y_j - t_j. \quad (6)$$

Рассмотрим ряд теорем, определяющих алгоритм обратного распространения ошибки [7-9].

Теорема 1.1. Для любого скрытого слоя i ошибка i -го нейронного элемента определяется рекурсивным образом через ошибки нейронов следующего слоя j

$$\gamma_i = \sum_{j=1}^m \gamma_j F'(S_j) \omega_{ij}, \quad (7)$$

где m – количество нейронов следующего слоя по отношению к слою i ; ω_{ij} – синаптическая связь между i -м и j -м нейроном различных слоев; S_j – взвешенная сумма j -го нейрона.

Используя результаты данной теоремы можно определить ошибки нейронов скрытого слоя через ошибки нейронов следующего слоя по отношению к скрытому слою [7-9].

Теорема 1.2. Производные среднеквадратичной ошибки по весовым коэффициентам и порогам нейронных элементов для любых двух слоев i и j многослойной сети определяются следующим образом

$$\frac{\partial E}{\partial \omega_{ij}} = \gamma_j F'(S_j) y_i, \quad \frac{\partial E}{\partial T_j} = -\gamma_j F'(S_j). \quad (8)$$

Следствие 1.1. Для минимизации квадратичной ошибки сети весовые коэффициенты и пороги нейронных элементов должны изменяться с течением времени следующим образом:

$$\omega_{ij}(t+1) = \omega_{ij}(t) - \alpha \gamma_j F'(S_j) y_i, \quad (9)$$

$$T_j(t+1) = T_j(t) + \alpha \gamma_j F'(S_j), \quad (10)$$

где α – скорость обучения.

Данное следствие является очевидным. Оно определяет правило обучения многослойных нейронных сетей в общем виде, которое называется *обобщенным дельта правилом*.

Алгоритм обратного распространения ошибки характеризуется эмпирическим выбором подходящего шага обучения, что может привести к медленной сходимости и неустойчивости процесса обучения.

В настоящее время существует множество модификаций алгоритма обратного распространения ошибки, которые базируются как на выборе подходящего шага обучения на каждой итерации алгоритма, так на применении различных методов оптимизации, позволяющих в той или иной степени устранить описанные выше недостатки. Рассмотрим различные модификации алгоритма обратного распространения ошибки.

С целью адаптации шага обучения в ряде работ используются эмпирические правила уменьшения его размера в процессе выполнения каждой обучающей итерации t . В работе [10] используется стратегия уменьшения шага α с каждой новой итерацией обучения. Изменение шага обучения выполняется по следующему эмпирическому правилу:

$$\alpha(t) = \alpha(0) / (1+t/r), \quad (11)$$

где $r > 0$ – параметр, подбираемый опытным путем.

В работе [11] предложено модифицировать веса нейронов в процессе обучения, используя уникальные значения шагов обучения $\alpha_{ij}(t)$ для каждого веса ω_{ij} . Адаптация этих шагов выполняется использованием двух последних градиентов. Для каждого веса нейронов сети инициализируются начальные значения шагов $\alpha_{ij}(0)$. Адаптация осуществляется по правилам:

$$\alpha_{ij}(t) = \alpha_{ij}(t-1)u, \quad \text{если } \frac{\partial E}{\partial \omega_{ij}}(t) \cdot \frac{\partial E}{\partial \omega_{ij}}(t-1) \geq 0, \quad (12)$$

$$\alpha_{ij}(t) = \alpha_{ij}(t-1)d, \quad \text{в противном случае.}$$

Модификация связей выполняется по формуле

$$\Delta \omega_{ij}(t) = -\alpha_{ij}(t) \cdot (\frac{\partial E}{\partial \omega_{ij}} + \varepsilon \cdot \Delta \omega_{ij}(t-1)). \quad (13)$$

Здесь u, d, ε – параметры обучения, подбираемые эмпирически.

В алгоритме обучения RPROP [11] с целью уменьшения осцилляций обучения применяется стратегия ограниченного локального шага обучения. При этом адаптация уникального

для каждого веса сети шага $\alpha_{ij}(t)$ выполняется по правилам (12) с учетом следующих ограничений:

$$\begin{aligned} \alpha_{ij}(t) &= \alpha_{\max}, \text{ если } \alpha_{ij}(t) \geq \alpha_{\max}, \\ \alpha_{ij}(t) &= \alpha_{\min}, \text{ если } \alpha_{ij}(t) \leq \alpha_{\min}. \end{aligned} \quad (14)$$

Модификация связей производится в соответствии со следующими выражениями:

если $\partial E / \partial w_{ij}(t) \partial E / \partial w_{ij}(t-1) \geq 0$ то:

$$\begin{cases} \Delta w_{ij}(t) = -\alpha_{ij}(t) \cdot d, & \text{если } \partial E / \partial w_{ij}(t) > 0 \\ \Delta w_{ij}(t) = +\alpha_{ij}(t) \cdot u, & \text{если } \partial E / \partial w_{ij}(t) < 0 \end{cases}$$

иначе $w_{ij}(t+1) = w_{ij}(t-1)$; $\partial E / \partial w_{ij}(t) = 0$ (15)

В данных работах приводятся оптимальные значения констант $\alpha_{\max}, \alpha_{\min}, u, d$, при использовании которых были получены наилучшие результаты обучения.

Несомненными достоинствами вышеописанных правил является их относительно малая вычислительная сложность. Однако наличие в них ряда констант обучения приводит к необходимости индивидуального подбора их значений опытным путем отдельно для каждой обучающей выборки, что является весьма трудоемким процессом. Аналогичные недостатки присущи методу сопряженных градиентов и методам второго порядка.

В ряде работ [7,9,12] предложены подходы для вычисления адаптивного шага обучения, который на каждой итерации алгоритма изменяется таким образом, чтобы минимизировать квадратичную ошибку. В том случае нет необходимости подбора шага обучения эмпирическим путем.

2. Подкрепляющее обучение

Подкрепляющее обучение (reinforcement learning) применяется в тех случаях, когда неизвестна обучающая выборка, но известен сигнал подкрепления (рис. 1).




Рис. 1. Подкрепляющее обучение.

Такой сигнал характеризует качество взаимодействия обучающего агента с внешней средой. Существует различные варианты подкрепляющего обучения [13]. Рассмотрим общую постановку задачи при использовании данного метода обучения.

Предположим, что агент, находящийся в состоянии $X(t)$ осуществляет акцию (управление) $Y(t)$. В результате он изменяет свое состояние

$$X(t+1) = F(X(t), Y(t)). \quad (16)$$

Качество изменения состояния агента характеризуется сигналом подкрепления (премией)

$$r(t+1) = R(X(t), Y(t)). \quad (17)$$

Цель подкрепляющего обучения – найти такое управление объектом, которое максимизирует кумулятивную сумму всех будущих премий

$$V(X(t)) = \sum_{i=t}^{\infty} \gamma^{i-t} r(i+1), \quad (18)$$

где $\gamma \in [0, 1]$ характеризует степень учета сигналов подкрепления (discount factor).

Существует два основных варианта подкрепляющего обучения: АНС обучение и Q-обучение [13].

АНС (адаптивное эвристическое управление) метод состоит из следующих частей: определение целевой функции $V(X)$; определение сигнала управления $Y(t)$, используя целевую функцию.

В соответствии с этим архитектура сети состоит из модуля критики и модуля управления (актор) (рис. 2).




Рис. 2. Архитектура АНС сети.

Задача «критика» состоит в формировании целевой функции и определении на основе её корректного внутреннего подкрепляющего сигнала r . «Актер» обучается отображать текущее состояние X в корректную акцию Y . Для обучения используется метод временной ошибки (ВО). Найдем соотношение между целевыми функциями $V(X)$ в два последовательных момента времени t и $t+1$. Тогда, используя выражение (18) получим

$$V(X(t)) = r(t+1) + \gamma V(X(t+1)). \quad (19)$$

Если последнее равенство не выполняется, то существует временная ошибка, которая определяется следующим образом:

$$\delta(t) = r(t+1) + \gamma V(X(t+1)) - V(X(t)). \quad (20)$$

Она характеризует ошибку прогнозирования подкрепляющего сигнала $r(t)$ при переходе от одного состояния в другое.

Основной алгоритм обучения критика состоит в минимизации квадратичной временной ошибки:

$$\delta^2 = \frac{1}{2} (r(t+1) + \gamma V(X(t+1)) - V(X(t)))^2. \quad (21)$$

Пусть, например, критик представляет собой линейную нейронную сеть с одним обрабатывающим элементом. Тогда выходное значение сети, которое соответствует целевой функции V , определяется, как

$$V(X(t)) = \sum_{i=1}^n v_i x_i(t). \quad (22)$$

Используя метод градиентного спуска, можно получить следующее выражение для модификации весовых коэффициентов v_i :

$$v_i(t+1) = v_i(t) + \alpha \delta(t) x_i(t), \quad (23)$$

где α - скорость обучения.

Рассмотрим обучение актора. Как уже отмечалось, задачей его является генерация подходящего действия в соответствии с текущей ситуацией. Пусть совокупность акций

$$Y(t) \in R^m. \quad (24)$$

Тогда структуру актора можно представить в виде двухслойной нейронной сети, выходной слой которой, содержит m нейронных элементов. При этом

$$y_j(t) = F\left(\sum_i \omega_{ij} x_i(t)\right), \quad (25)$$

где в качестве F можно использовать пороговую функцию активации.

Весовые коэффициенты изменяются только для нейронного элемента, выходное значение которого равняется единице. Для этого можно использовать следующее правило [13]:

$$\begin{aligned} \omega_{ij}(t+1) &= \omega_{ij}(t) + \alpha \delta(t) x_i(t), \text{ если } y_j = 1 \\ \omega_{ij}(t+1) &= \omega_{ij}(t), \text{ иначе.} \end{aligned} \quad (26)$$

Таким образом, временная ошибка является главным обучающим сигналом как для критика, так и для актора.

Как уже отмечалось, вторым вариантом подкрепляющего обучения является Q -обучение [13]. В этом случае пространство акций является дискретным и определяется функция $Q(X, Y)$, которая характеризует качество акции Y , когда агент находится в состоянии X . Для каждой акции Y существует отдельная функция $Q(X, Y)$. Чем больше будущая награда за осуществление акции, тем больше значение функции Q . Алгоритм обучения корректным значениям функции Q получается из уравнения Беллмана и базируется на минимизации временной ошибки

$$\begin{aligned} \delta^2(t) &= \frac{1}{2} (r(t+1) + \\ &+ \gamma \max_y Q(X(t+1), Y) - Q(X(t), Y))^2 \end{aligned} \quad (27)$$

Тогда

$$Q(X(t+1), Y(t+1)) \leftarrow Q(X(t), Y(t)) + \alpha \delta(t), \quad (28)$$

где

$$\delta(t) = r(t+1) + \gamma \max_Y Q(X(t+1), Y) - Q(X(t), Y) \quad (29)$$

В процессе обучения исследуются различные акции. После обучения акция выбирается в соответствии со следующим критерием:

$$Y = \arg \max_{l \in Y} Q(X, l), \quad (30)$$

где Y – дискретное множество возможных акций.

Основной недостаток подкрепляющего обучения является его большая трудоемкость, что будет показано в следующих разделах.

3. Обучение без учителя

В соответствии с данным методом обучения нейронная сеть учится формировать выходное пространство решений только на основе входных воздействий (рис. 3).




Рис. 3. Обучение без учителя.

К таким сетям традиционно относят различные варианты ассоциативной памяти (сеть Хопфилда, Хэмминга, двусторонняя ассоциативная память, сети адаптивного резонанса), нейронные сети Кохонена и рециркуляционные нейронные сети [7,9].

Существуют различные варианты обучения без учителя. Так в ассоциативной памяти наиболее распространенным методом обучения является правило Хебба [9], которое имеет биологические предпосылки. Согласно этому правилу, обучение происходит в результате усиления силы связи (синаптического веса) между одновременно активными нейронами. Исходя из этого, часто используемые в сети связи усиливаются, что объясняет феномен обучения путем повторения и при-

выкания. В математической форме правило обучения Хебба можно представить следующим образом:

$$\omega_{ij}(t+1) = \omega_{ij}(t) + x_i y_j, \quad (31)$$

где t – время; x_i и y_j – соответственно выходные значения i -го и j -го нейронов; ω_{ij} – сила связи между i -м и j -м нейронами.

В начальный момент времени предполагается, что

$$\omega_{ij}(t=0) = 0, \quad \forall i, j. \quad (32)$$

Нейронные сети Кохонена [14] осуществляют топологическое упорядочивание входного пространства образов. Для их обучения используется конкурентный метод. В соответствии с ним для нейрона-победителя синаптические связи усиливаются, а для остальных нейронов не изменяются. При этом модификация связей происходит с целью минимизации квадратичной ошибки нейрона-победителя:

$$E = \frac{1}{2} \sum_i (\omega_{in} - x_i)^2 \quad (33)$$

Тогда в соответствии с методом градиентного спуска изменение весовых коэффициентов нейрона-победителя осуществляется следующим образом:

$$\omega_{in}(t+1) = \omega_{in}(t) + \gamma (x_i - \omega_{in}), \quad (34)$$

где γ – скорость обучения.

Следующей парадигмой, применяемой при обучении без учителя, является максимизация взаимной информации между входами и выходами сети [15]. Взаимная информация $H(X, Y)$ характеризует уменьшение неопределенности в отношении X при получении сведений об Y

$$H(X, Y) = H(X) - H(X/Y), \quad (35)$$

где $H(X)$ – энтропия входных сигналов X , $H(X/Y)$ – условная энтропия X относительно Y .

Условная энтропия $H(X/Y)$ характеризует степень неопределенности X , после того как состояние системы Y полностью определилось.

Следует отметить, что максимизация последнего выражения эквивалентна

$$\max H(X, Y) \sim \min H(X/Y) \sim \max H(Y). \quad (36)$$

При применении данного подхода к линейной рециркуляционной нейронной сети можно получить Ойя – правило [16], которое эквивалентно методу главных компонент [9] и базируется на том, что максимизация взаимной информации эквивалентна минимизации суммарной среднеквадратичной ошибки между входным и реконструированным образами

$$\max H(X, Y) \sim \min E_s, \quad (37)$$

где E_s – суммарная квадратичная ошибка:

$$E_s = \frac{1}{2} \sum_{k=1}^L \sum_{i=1}^n (\bar{x}_i^k - x_i^k)^2. \quad (38)$$

Здесь \bar{x}_i^k , x_i^k – соответственно i -ая компонента реконструированного и исходного k -го образа.

Для линейной рециркуляционной сети

$$\bar{x}_i = \sum_{j=1}^P \omega_{ji} y_j, \quad (39)$$

где y_j – j -ая компонента сжатого образа.

Квадратичная ошибка для одного образа определяется как

$$E = \frac{1}{2} \sum_{j=1}^n (\bar{x}_i - x_i)^2. \quad (40)$$

Тогда в соответствии с методом градиентного спуска

$$\frac{\partial E}{\partial w'_{ji}} = \frac{\partial E}{\partial x_i} \frac{\partial x_i}{\partial w'_{ji}} =$$

$$= -(x_i - \bar{x}_i) y_j = -y_j (x_i - \sum_{j=1}^p w'_{ji} y_j) \quad (41)$$

Отсюда получается Ойя правило для обучения рекуррентной сети

$$w'_{ji}(t+1) = w'_{ji}(t) + \alpha y_j (x_i - \sum_{j=1}^p w'_{ji} y_j). \quad (42)$$

В соответствии с методом главных компонент [9] матрица весовых коэффициентов W прямого слоя

$$W = (W')^T \quad (43)$$

Тогда правило изменения весовых коэффициентов прямого слоя можно представить как

$$w_{ij}(t+1) = w_{ij}(t) + \alpha y_j \left(x_i - \sum_{j=1}^p w_{ij} y_j \right). \quad (44)$$

Теоретически доказано [16], что Ойя-правило эквивалентно методу главных компонент, однако его применение приводит к слишком длительной процедуре обучения.

Заключение

В работе рассмотрены основные парадигмы обучения нейронных сетей: обучение с учителем, подкрепляющее обучение и обучение без учителя. Проведен анализ алгоритмов обратного распространения ошибки, АНС и Q -обучения, правила Хебба, конкурентного обучения и правила Ойя.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. McCulloch W., Pitts W. A logical calculus of the ideas immanent in nervous activity // Bulletin of Mathematical Biophysics. - 1943. - N5. - P. 115 - 133.

УДК 681.324:519.711.7

Гладкий И.И., Маньяков Н.В., Махнист Л.П.

ТЕОРЕТИЧЕСКИЕ ОСНОВЫ АЛГОРИТМОВ ОБУЧЕНИЯ ГЕТЕРОГЕННЫХ НЕЙРОННЫХ СЕТЕЙ ДВУХСЛОЙНОЙ АРХИТЕКТУРЫ

1. ВВЕДЕНИЕ

Двухслойные нейронные гетерогенные сети прямого распространения являются наиболее используемым классом нейронных сетей. Более 80% прикладных задач, решаемых в нейросетевом базисе, используют данный тип архитектуры [1]. Широкое применение таких сетей основано на способности данного класса сетей быть универсальным аппроксиматором [2], что позволяет любую задачу приближения решать с их использованием. Их применение встречается в задачах прогнозирования, классификации, кластеризации, управления

и многих других. В связи с этим возникает вопрос о создании эффективной методики их обучения.

2. ЗАДАЧА ОБУЧЕНИЯ ДВУХСЛОЙНОЙ СЕТИ И ЕЕ МАТРИЧНАЯ АЛГОРИТМИЗАЦИЯ

Рассмотрим двухслойную гетерогенную нейронную сеть, состоящую из m_0 нейронных элементов распределительного слоя, m_1 нейронов скрытого слоя и m_2 – выходного слоя (рис.1).

Гладкий Иван Иванович, ст. преподаватель каф. высшей математики Брестского государственного технического университета.

Маньяков Николай Владимирович, ст. преподаватель каф. высшей математики Брестского государственного технического университета.

Махнист Леонид Петрович, к.т.н., доцент каф. высшей математики Брестского государственного технического университета.

Беларусь, БГТУ, 224017, г. Брест, ул. Московская, 267.

Машиностроение, автоматизация, ЭВМ