

УДК 007:612.82:681.3.01

МНОГОСЛОЙНАЯ НЕЙРОННАЯ СЕТЬ С РАНДОМИЗИРОВАННЫМ ОБУЧЕНИЕМ: МОДЕЛЬ И ПРИЛОЖЕНИЯ

С.А. Терехов

В работе рассмотрена рандомизированная схема имитации отжига для обучения многослойной нейронной сети. Исследуются фрактальные свойства обучающих траекторий в фазовом пространстве сети. Предложено управление температурой обучения на основе феноменологических характеристик траектории. Проведено сравнение ошибки обобщения многослойного персептрона и сплайн-интерполяции на задаче прогноза временных рядов. Показано, что для негладких функций, порождающих стохастический временной ряд, нейронная сеть предпочтительнее сплайна при равном числе параметров.

Схема обучения применена для построения кибернетической нейросетевой модели явления магнитной кумуляции, а также для классификации отказов в системе охлаждения реактора АЭС.

ВВЕДЕНИЕ

Многочисленные достоинства сетей из искусственных нейроподобных элементов [1], как то высокий уровень параллельности вычислений, способность к настройке на конкретную информационную задачу, основываясь непосредственно на исходной информации, а также способность к выявлению скрытых ее свойств и обобщения их на новые исходные условия, сегодня широко известны. Уровень теоретического понимания этих и других особенностей нейронных сетей приводит к постепенному смещению пика актуальности исследований в сторону разработки прикладных систем.

Ориентация на приложения, а именно это характерно для данной работы, требует, в частности, усилий по следующим направлениям:

- Исследования в области схем обучения общего назначения, каковыми являются, например, рандомизированные схемы [2, 3, 4, 5];
- Качественные исследования устойчивости нейросистем к шумам иискажениям в исходной информации, а также способности к обобщению. Последнее широко исследовано только для простых сетей типа классического персептрона [6, 7]. Устойчивость ряда распознавающих систем к шумам рассмотрена в [8];

- Анализ способов представления информации для нейросистем и формулировки информационных задач. Подобные исследования в этой области выполнены в НИИ Нейрокибернетики Ростовского университета [9] и в Институте Прикладной Физики в Нижнем Новгороде [10].

Часть из перечисленных вопросов рассмотрена и в предлагаемой статье. Изложение построено следующим образом. В первой части работы обсуждается архитектура наиболее часто используемой в приложениях многослойной нейронной сети без обратных связей. Подробно рассмотрена общая рандомизированная схема обучения для такой сети, фрактальные свойства обучающих траекторий и обучение с понижением синаптической активности. Здесь также исследована зависимость оценки ошибки обобщения от объема исходной информации и сложности нейросети. Численные эксперименты выполнены для задачи прогноза различных временных последовательностей. Ошибка обобщения сравнивается с ошибкой сплайн-интерполяции, выполненной на той же выборке. Обнаружено, что при одинаковом числе параметров нейросеть оказывается предпочтительнее сплайна для негладких функций, порождающих временной ряд.

Во второй части работы описана нейросистема PERCY и ее применение к задачам детектирования неисправностей в системе охлаждения атомного реактора [11] и моделирования магнитогазодинамического течения с кумуляцией энергии [12].

1. МОДЕЛЬ НЕЙРОННОЙ СЕТИ И РАНДОМИЗИРОВАННАЯ СХЕМА ОБУЧЕНИЯ

1.1. Архитектура нейронной сети

Рассматриваемая в этой работе нейронная сеть представляет собой многослойный персептрон [6] с произвольным количеством нейронов N_I на каждом слое (см.рис.1). Популярность многослойного персептрона объясняется, по-видимому, его наглядностью и универсальностью решаемых им задач. Персептрон с несколькими промежуточными слоями нейронов между входами и выходами способен выполнять аддитивную классификацию в пространстве образов даже в случае многосвязных классов.

Активность нейроподобных элементов описывается аналоговыми переменными $S_{Ij} \in [0, 1]$. Первый индекс определяет номер слоя, второй — номер элемента в слое. Элементы с нулевым вторым индексом имеют постоянную активность, равную единице, что соответствует введению порога. Синаптические связи $W_{Ii;Jj}$ для каждого узла S_{Jj} следующего слоя образуются со всеми узлами предыдущего слоя $I = J - 1$.

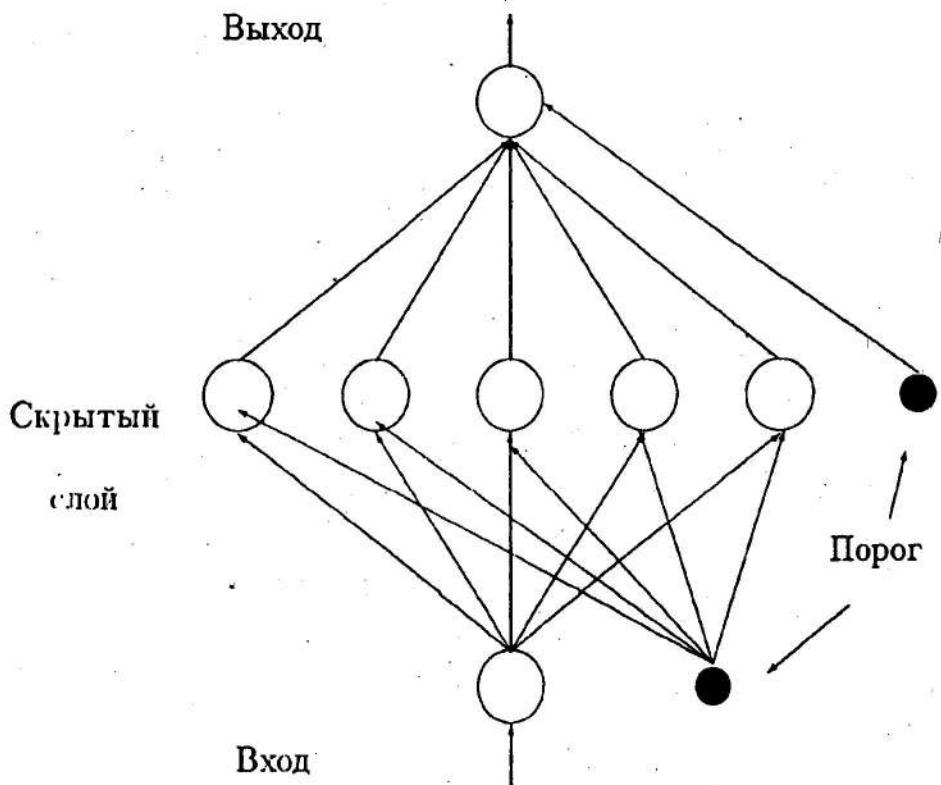


Рис. 1. Архитектура многослойной нейронной сети с одним входом, одним выходом и 5 нейронами в скрытом слое.

Элементы одного слоя функционируют синхронно, с последовательным переходом возбуждения на следующие слои, согласно выражению

$$S_{(I+1)j} = f \left(\sum_{j=0}^{N_I} W_{Ij(I+1)j} \cdot S_{Ij} \right). \quad (1)$$

Здесь $f : R \mapsto [0, 1]$ — переходная функция активации нейрона. В приложениях часто используется так называемая сигмоидальная функция $f(x) = (1 + \exp(-\gamma x))^{-1}$ и пороговая функция $f(x) = \frac{1}{2}(1 + \text{sign}(x))$, являющаяся пределом сигмоидальной f при $\gamma \rightarrow \infty$.

Значения элементов нижнего (нулевого) слоя S_{0j} равны входному вектору \mathbf{X}_j . Выходной вектор \mathbf{Y}_i соответствует активности нейронов верхнего слоя — высшего слоя иерархии. Таким образом, многослойный персепtron осуществляет некоторое функциональное преобразование $G : \mathbf{X}_j \mapsto \mathbf{Y}_i$. Какое именно выполняется преобразование, определяется значением синаптических весов W (и, конечно, топологией сети). Задача обучения нейронной сети состоит в синтезе требуемой функции G путем подстройки значений W .

1.2. Рандомизированное обучение

При выбранной топологии нейронной сети остается произвол в значениях весов связей $W_{I;J}$ между нейроподобными элементами, а также порогов их передаточных функций W_{I0} . Настройка их значений для выполнения конкретных заданий определяет многообразие решаемых сетью информационных задач.

В общем виде задача формулируется следующим образом [13]. Пусть имеется p пар образов $\{I^\alpha, O^\alpha\}$, $\alpha = 1..p$, $O_i^\alpha, I_i^\alpha \in [0, 1]$. Требуется указать значения весов и порогов W всех нейронов сети, при которых уровни возбуждения выходных элементов равны или близки к O^α всякий раз, когда на входной слой подается I^α . Пары $\{I, O\}$ называются обучающей выборкой.

Данная задача является вариантом обучения с учителем, т.к. известно правильное значение выходов сети и имеется оценка ошибки $E(W)$, совершающейся сетью. Эта оценка является функцией состояния сети:

$$E(W) = \sum_i \sum_\alpha \|F(I^\alpha; W)_i - O_i^\alpha\|^2, \quad (2)$$

где $F(I^\alpha; W)$ — реакция сети на образ I^α в состоянии W . Такой выбор функции состояния $E(W)$ не является единственным. Так, например, в приложениях также используется функционал направленного расхождения [14]

$$E(W) = \sum_i \sum_\alpha \left(\frac{F(I^\alpha; W)_i}{O_i^\alpha} - 1 - \ln \frac{F(I^\alpha; W)_i}{O_i^\alpha} \right). \quad (3)$$

Задача обучения сводится к минимизации ошибки обучения E , выбранной в той или иной форме.

Для обучения многослойных сетей нейронов с сигмоидальными переходными функциями предложен эффективный алгоритм обратного распространения ошибок [15]. В нем минимизация E выполняется на основе градиентного метода. Процедура градиентного спуска заканчивается в одном из локальных минимумов E , при этом полное обучение не гарантируется. Для преодоления этого недостатка предложен ряд алгоритмов [3]. Мы остановимся на варианте направленного рандомизированного поиска $\min E$, получившего название имитации отжига [2].

Подход имитации отжига состоит в построении блуждающих траекторий в конфигурационном пространстве весов связей (схема Метрополиса с изменяющейся температурой), последовательно приближающихся к минимуму энергии, в качестве которой выбирается интегральная ошибка решения задачи распознавания (2). На каждом шаге в схеме имитации отжига выбирается наудачу параметр W_i , и разыгрывается его новое значение по формуле:

$$\tilde{W}_i = W_i + h \cdot (2\sigma - 1), \quad (4)$$

где σ — случайное число, лежащее в диапазоне значений $[0, 1]$, h — величина шага, задаваемая в качестве параметра. Далее, в соответствии со схемой Метрополиса, определяется приемлемость нового значения веса в зависимости от энергии (2) нового состояния. Если энергия в результате изменения веса уменьшилась ($\tilde{E} < E$), новое состояние безусловно принимается и процедура повторяется. В случае возрастания энергии ($\delta E > 0$) новое состояние принимается с Больцмановской вероятностью $\exp(-\delta E/T)$, а в противном случае отвергается. Параметр T , являющийся функцией времени обучения, имеет смысл статистической температуры.

Процедура имитации отжига приводит к сходимости по вероятности к глобальному минимуму E . Однако в приложениях часто приходится довольствоваться состояниями, не являющимися в полном смысле глобальными минимумами, т.к. скорость сходимости и, соответственно, длина обучающей траектории заранее неизвестны.

Данная схема обучения является общей для сетей различных топологий, однако при этом подходе остаются открытыми по меньшей мере три вопроса: 1) каким должен быть темп понижения температуры для получения коротких траекторий; 2) как избавиться от возможного неограниченного роста весов сети при рандомизированном поиске; и 3) каков будет характер поведения сети при предъявлении ей новой для нее информации, другими словами, какова будет ошибка обобщения. Ниже мы последовательно остановимся на этих вопросах.

1.3. Фрактальные свойства обучающих траекторий

В методе имитации отжига изменение температуры является единственным внешним управлением для процесса обучения. На начальном этапе обучения [2] температура должна быть достаточно большой, чтобы гарантировать отсутствие локализации траекторий в локальных минимумах (в этом, собственно, и состоит основное достоинство рандомизированных схем). В дальнейшем температуру следует медленно понижать, имитируя процесс отжига металлов, с тем чтобы система "замерзала" в области притяжения глобального минимума, отвечающего наименьшей ошибке обучения.

Управление температурой должно быть близким к оптимальному в том смысле, что построенная блуждающая траектория в конфигурационном пространстве весов и порогов должна иметь наименьшую длину, т.е. минимизировать время обучения.

Широко применяется обратно-степенной закон понижения T

$$T(t) = \frac{1}{1 + t^\beta}, \quad (5)$$

где t — время обучения, измеренное в шагах Монте-Карло на синапс, β — показатель темпа понижения температуры. Данное соотношение

может быть обосновано только для истинно термодинамических систем с небольшим отклонением от равновесия. Нейронная сеть в произвольном состоянии W далека от равновесия.

Форма энергетической поверхности, определяемой соотношением (2), при большом объеме обучающей выборки и сложной топологии сети является весьма неоднородной. Она состоит из множества оврагов, холмов с крутыми и пологими склонами, а также долин постоянной энергии. Путешествие по данной поверхности происходит по искривленным путям. В нашей работе [5] обнаружено, что получающиеся траектории демонстрируют фрактальные свойства, и предложена локальная мера, переходящая во фрактальную размерность в пределе бесконечно длинной траектории.

Хорошо известно [16], что свободная Броуновская частица, блуждающая в фазовом пространстве, описывает траекторию с фрактальной размерностью $D = 2$, так как длина траектории L оказывается пропорциональной квадрату перемещения R : $L \approx h \cdot (R/h)^D$, $D = 2$ (здесь h — шаг блуждания).

Вынужденное блуждание по энергетической поверхности при обучении нейронной сети может быть описано предфрактальной (по Мандельброту) размерностью

$$D_s = M \left(\frac{\ln L(W, W')}{\ln R(W, W')} \right). \quad (6)$$

Для вычисления локального значения D_s выбирается физически значимый отрезок траектории $W \rightarrow W'$ вблизи состояния W . Математическое ожидание M берется по всем реализациям стохастического процесса блуждания Метрополиса между состояниями W и W' . В приложениях для оценки D_s можно использовать значение, полученное на одной реализации отрезка траектории.

Введенная размерность переходит в размерность Хаусдорфа в пределе длинных траекторий:

$$\lim_{L \rightarrow \infty} D_s = D. \quad (7)$$

Можно выделить различные варианты поведения размерности при изменении температуры [5].

- $T \rightarrow 0$ ($T \ll \bar{E}$), $D_s \approx 1$. Обучение заканчивается в точке ближайшего локального минимума.
- $T \gg \bar{E}$. Свободное Броуновское блуждание, $D_s \approx D = 2$, состояние обучения не достигается.
- $T = T_c(t)$ ($D_s = D_{sc}$). Блуждание при критической температуре, соответствующей оптимальному управлению. Математическое ожидание длины обучающей траектории минимально.

Для оптимального обучения могут также быть использованы еще две феноменологические характеристики: $(\Delta \bar{E})_+^2$ — локальное среднеквадратичное изменение энергии вдоль траектории (т.е. среднее по принятым шагам блуждания), и $(\Delta \bar{E})_-^2$ — соответствующее среднее для отвергнутых шагов, в схеме испытаний Метрополиса. Образно картина выглядит следующим образом. Обучающая траектория представляет собой длинный извилистый путь к одной из низколежащих долин. При этом локальная фрактальная размерность $D_s(W)$ является мерой искривленности траектории в данной точке W , $(\Delta \bar{E})_+^2$ — мерой крутизны спуска (подъема) вдоль траектории, а $(\Delta \bar{E})_-^2$ — характерной глубиной оврага, в котором расположена траектория. Эти три феноменологические величины зависят одновременно и от формы энергетической поверхности, и от температуры обучения. Последнюю зависимость можно использовать для адаптивного управления температурой в процессе обучения для получения близких к оптимальным траекторий. Так, например, при большой величине $(\Delta \bar{E})_+^2$ и малой D_s , температура может быть понижена, что соответствует движению вдоль градиента; наоборот при $(\Delta \bar{E})_+^2 \ll (\Delta \bar{E})_-^2$ и большой D_s , траектория находится в области минимума. Здесь тактика обучения зависит от абсолютного значения E . При неприемлемо больших ошибках E требуется увеличение температуры.

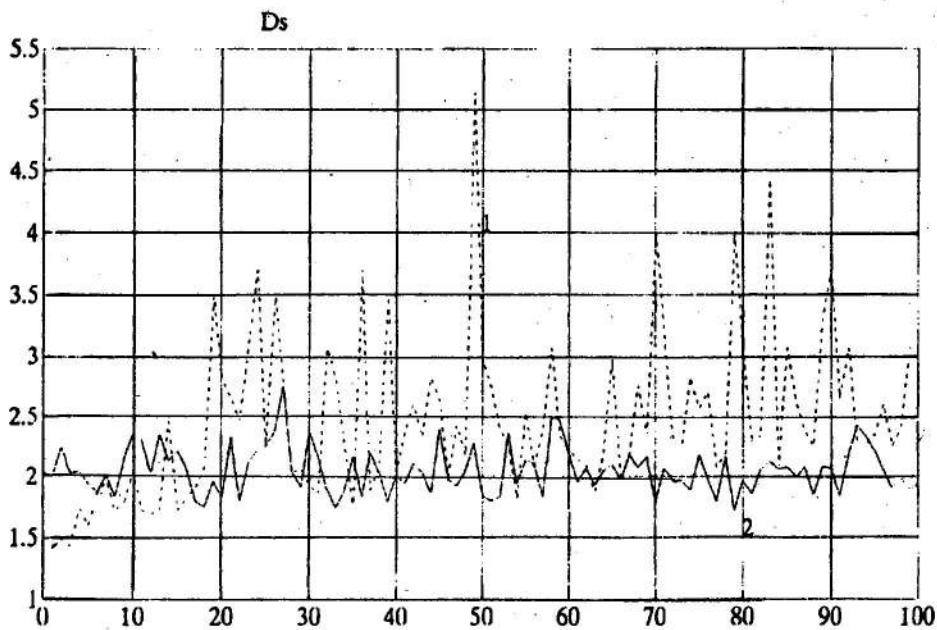


Рис. 2. Изменение локальной фрактальной размерности при движении по обучающей траектории. (1) — низкие температуры, (2) — высокие температуры.

На рис.2 приведен характер вариаций локальной фрактальной размерности вдоль траектории для двух предельных случаев: замерзание си-

стемы в локальном минимуме при малых температурах (кривая 1) и эргодическое свободное блуждание с $D_s \approx 2$ при высоких температурах.

1.4. Обучение с понижением интегральной синаптической активности

Важным практическим аспектом при проектировании аппаратных реализаций нейронных сетей является обоснование возможности решения требуемой задачи распознавания при общей минимальной активности в сети [17, 18]. При этом оптимально распределяются энерго- и другие затраты на поддержание активности синаптических связей, а также минимизируется количество обрабатываемой в сети информации. Данный принцип, можно надеяться, соответствует экономности биологических систем при решении информационных задач.

В ряде исследований рассматриваются механизмы уменьшения числа активных синапсов. В работе [19] показано, что в модели Хопфилда даже при сокращении на 90% числа связей сохраняется способность сети к консервации ассоциативной памяти и решению задачи распознавания. В серии работ [20, 21] сообщается, что направленное уменьшение количества связей в многослойной сети приводит также к снижению ошибки обобщения.

Таблица 1

Ошибка обучения и интегральная синаптическая активность при δ -регуляризации в зависимости от величины δ

	$\delta = 0$	$\delta = 10^{-4}$	$\delta = 10^{-3}$	$\delta = 10^{-2}$	$\delta = 10^{-1}$
$(1/N) \sum \ W_i\ ^2$	32.5	4.12	9.9	1.36	0.19
E	0.077	0.084	0.061	0.056	0.067

В данной работе предлагается добавить к обычно используемому функционалу энергии, как меры суммарной ошибки при решении задачи распознавания, δ -член, отвечающий понижению полной синаптической активности:

$$\tilde{E}(W) = E(W) + \delta \cdot \sum_{i,j} \|W_{ij}\|^2. \quad (8)$$

Введение внешнего торможения роста синапсов соответствует использованию химпотенциала в статистическом моделировании. Впервые обучение с δ -регуляризацией было рассмотрено авторами работы [7] для однослоевой сети. Нами проведено экспериментальное исследование влияния δ -регуляризации на ошибку обучения многослойного персептрона. Для этой цели выполнена серия расчетов по обучению сети из трех слоев

с числом нейронов 1–4–1 на задаче представления логической кривой (подробнее см. следующий пункт). Полное число параметров сети было равно 13, обучающая выборка состояла из 15 образов — точек на логистической кривой. Расчеты, проведенные для пяти различных значений δ , представлены в табл.1. Величины ошибки обучения и δ -члена приведены после 50 шагов Монте–Карло на синапс.

Видно, что введение регуляризации значительно (на два порядка) снижает активность, не приводя при этом к увеличению ошибки обучения вплоть до $\delta = 0.1$. Это обстоятельство весьма ценно для приложений, т.к. низкая интегральная синаптическая активность обеспечивает малые энергозатраты в аппаратных нейросистемах и позволяет для хранения весов использовать память с малым числом разрядов.

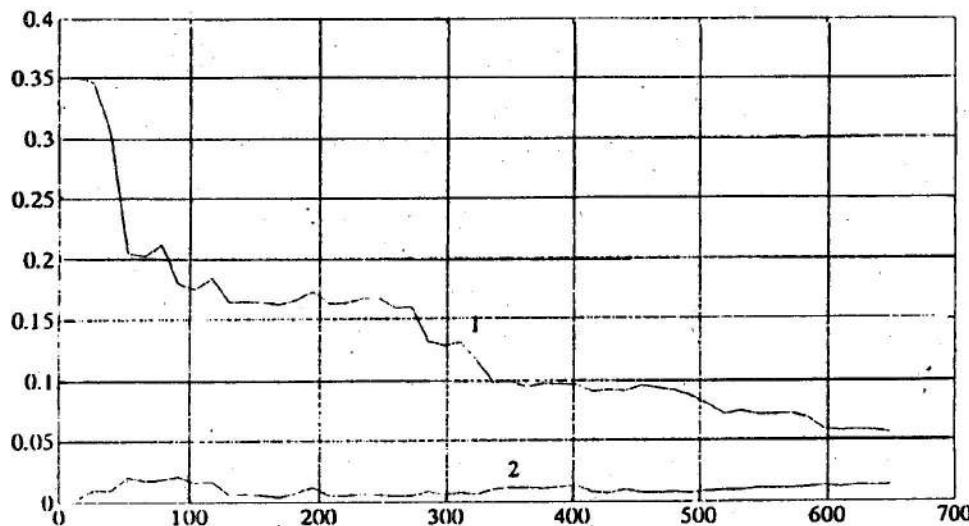


Рис. 3. Зависимость ошибки обучения (1) и интегральной синаптической активности (2) нейронной сети от времени обучения в МК-шагах на синапс.

На рис.3 показано характерное поведение ошибки обучения E и δ -члена от времени.

1.5. Оценка ошибки обобщения при randomизированном обучении

При выборке достаточного числа скрытых слоев и числа нейронов в них ошибка обучения (2) может быть в принципе сделана сколь угодно малой. Для этого достаточно, чтобы рассматриваемое отображение из пространства входов X в пространство выходов Y принадлежало к весьма широкому классу представимых многослойной сетью отображений. Вопрос заключается в том, насколько эффективно требуемое отображение

может быть построено по конечному числу примеров из обучающей выборки. Другими словами, насколько хорошо нейронная сеть будет соответствовать требуемому отображению на новых образах.

Количественная мера степени обобщения может быть введена, если известны все пары новых (тестовых) образов, в частности, если известно само отображение. Ошибка обобщения в этом случае также дается выражением (2) с той разницей, что суммирование по α проводится по новым образам. В случае бесконечного пространства образов ошибка обобщения понимается как предел оценки по увеличивающейся тестовой выборке.

В работе [2] получена характерная оценка ошибки обобщения, делающей однослойной сетью:

$$\epsilon \sim \left(\frac{p + N}{p - N} \right) E, \quad p > N, \quad (9)$$

где p — объем обучающей выборки, N — число переменных параметров (синапсов и порогов) сети, E — ошибка обучения. Нашей целью в этом пункте будет получение аналогичного (9) скейлинга в случае многослойной сети на основе компьютерного моделирования.

Для исследований был выбран класс задач, связанных с прогнозом поведения хаотических временных рядов. Задачи такого рода возникают в приложениях [22]. Рассмотрим ряд, генерируемый Марковским отображением

$$x_{n+1} = g(x_n), \quad n = 0, 1, \dots \quad (10)$$

Рекуррентный процесс (10) может быть представлен нейронной сетью с тремя слоями с числом нейронов, соответственно, $1 - k - 1$ (при этом общее число параметров $N = 3k + 1$). На вход сети подается значение x_n , требуемый выход должен быть равен x_{n+1} . Для обучения сети согласно (10) определялся набор пар (x_n, x_{n+1}) , из которого в каждом расчете использовались первые p пар. После достижения обученного состояния с ошибкой $E < 0.5\%$ или максимального числа историй (шагов Монте-Карло на синапс) $t = 100$, полученное значение ошибки обучения E сравнивалось с ошибкой обобщения ϵ . Последняя определялась по результатам большого числа испытаний (> 500) на новых точных данных по формуле (10). Далее объем обучающей выборки p увеличивался. Таким образом были получены зависимости ϵ и E от N и p .

Все исследования были выполнены для двух существенно отличающихся по характеру функций $g(x)$ — гладкой логистической кривой и кусочно-линейной кривой с большим числом точек разрыва.

1.5.1. Результаты для логистической кривой. Логистическая функция имеет вид

$$x_{n+1} = 4x_n(1 - x_n). \quad (11)$$

Задаваемый этой кривой итерационный процесс $x(n)$ имеет хаотический характер. Обе стационарные точки (решения квадратного уравнения (11) $x = 0$ и $x = 3/4$) являются неустойчивыми ($|dx_{n+1}/dx_n| > 1$). Результаты представления этого процесса нейронной сетью отражены в табл.2.

На рис.4 показан ход стохастического процесса (11) и результаты прогнозирования при помощи нейронной сети.

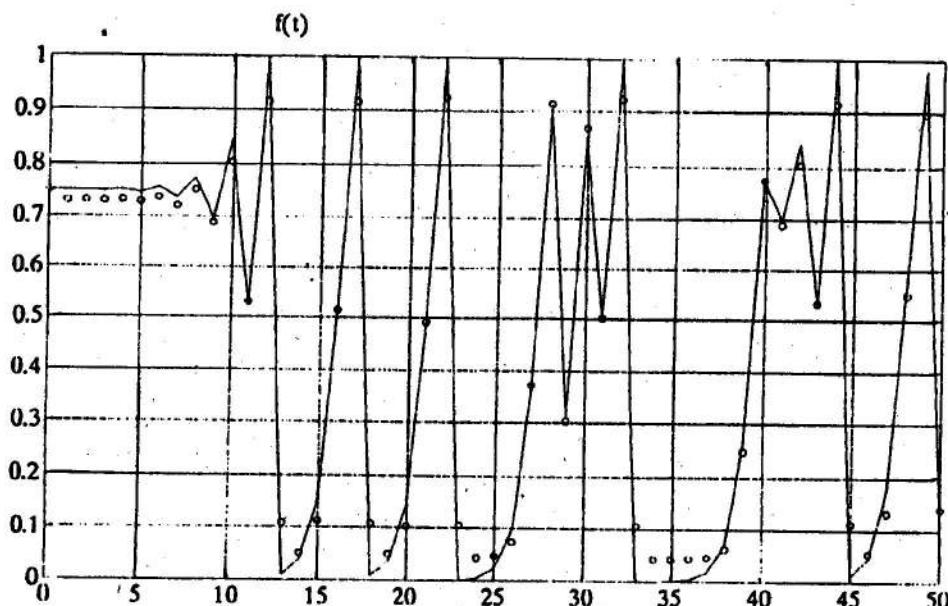


Рис. 4. Прогноз логистического стохастического временного процесса, выполняемый искусственной нейронной сетью. Сплошная линия — исходный процесса, о о о — прогноз.

В плоскости (x_{n+1}, x_n) логистическая кривая может быть легко заинтегрирована. Соответствующая относительная ошибка для кубического сплайна η_s также приведена в табл.2. Сплайн строился по тем же p точкам обучающей выборки. Заметим, что число параметров сплайна равно числу точек $N_s = p$. Практический интерес представляет сравнение ошибки обобщения нейронной сети с интегральной ошибкой, делаемой алгоритмами интерполяции при одинаковом числе параметров $N_s = N$. Соответствующие зависимости приведены на рис.5 (кривые 1 и 2). Видно, что в случае гладкой кривой, порождающей стохастический временной ряд, использование сплайн-интерполяции предпочтительнее. Ошибка сплайна набирается в основном в областях экстраполяции, а в случае нейронной сети ошибка распределается равномерно.

Данные табл.2 по ошибке обобщения нейронной сети в целом описы-

ваются зависимостью

$$\epsilon = \eta(N, p) \cdot E \sim \left(\frac{p + \tilde{N}}{p - \tilde{N}} \right) E, \quad p > N, \quad (12)$$

которая соответствует выражению (9) с заменой $N \mapsto \tilde{N} = \gamma N$, где $\gamma < 1$ — доля эффективно используемых связей. Значение этого параметра для логистической кривой составило $\gamma \approx 0.58$.

Таблица 2

Представление логистической кривой нейронной сетью,
 $\eta(N, p) = \epsilon(N)/E(N)$ — отношение ошибки обобщения к ошибке
 обучения при указанных N и p , η_s — отношение ошибки сплайна к
 ошибке обобщения нейронной сети

	$p = 4$	$p = 10$	$p = 16$	$p = 25$	$p = 40$
$\eta(N = 4)$	42.6	2.6	2.8	2.3	1.7
$\eta(N = 10)$	4.9	2.4	1.9	1.6	1.6
$\eta(N = 16)$	20.4	3.3	2.6	2.1	1.6
$\eta(N = 25)$	39.1	2.9	2.5	1.8	1.4
$\eta(N = 40)$	3.8	3.6	2.7	2.7	1.8
η_s	23.8	0.15	0.08	0.18	0.004

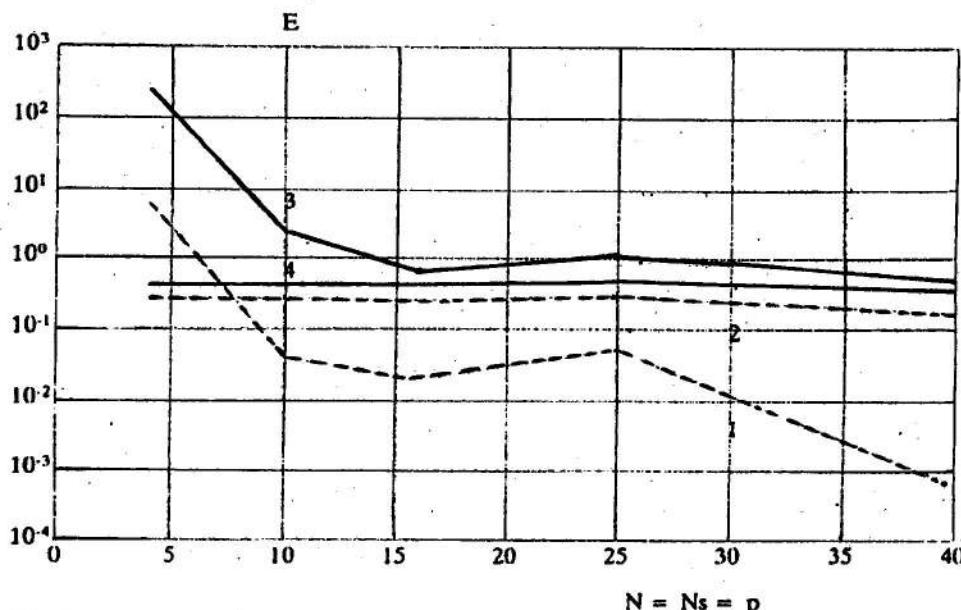


Рис. 5. Зависимость ошибки представления временного ряда сплайном и магнитослойной нейронной сетью от числа свободных параметров. (1) — логистический процесс, сплайн; (2) — логистический процесс, нейронная сеть; (3) — линейно-конгруэнтный датчик случайных чисел, сплайн; (4) — линейно-конгруэнтный датчик случайных чисел, нейронная сеть.

1.5.2. Результаты для линейно-конгруэнтного датчика псевдослучайных чисел. Вторым рассмотренным примером процесса (10) является используемый для построения последовательностей псевдослучайных чисел линейно-конгруэнтный метод [23]:

$$z_{n+1} = (a \cdot z_n + c) \bmod m; \quad x_{n+1} = z_{n+1}/m, \quad (13)$$

где параметры a , c и m могут быть выбраны натуральными числами на основе рекомендаций работы [23], z_n — целые числа в диапазоне $(0, m-1)$. При больших a и m кривая (13) представляет собой семейство множества параллельных отрезков, заштриховывающих единичный квадрат в плоскости (x_n, x_{n+1}) . В нашем случае достаточно сложная зависимость получается при $a = 7$, $c = 5$, $m = 17$. Все 6 стационарных точек процесса неустойчивы ($|dx_{n+1}/dx_n| = a > 1$). В отличие от логистической кривой, зависимость (13) приводит к большим ошибкам при интерполяции сплайнам.

Результаты моделирования, аналогичные данным предыдущего пункта, представлены в табл.3.

Сравнение нейронной сети кубического сплайна при одинаковом числе параметров $N_s = N$ также приведено на рис.5 (кривые 3 и 4). Здесь ситуация обратная: сплайн значительно уступает нейронной сети.

Ошибка обобщения по данным табл.3 в целом тоже укладывается в зависимость (12) с долей эффективно используемых связей $\gamma \approx 0.37$.

Подведем некоторые итоги первой части. Описанная нейронная сеть принадлежит к классу многослойных персепtronов. Задача обучения такой сети сформулирована в общем виде, как задача поиска минимума функционала ошибки. Для решения этой задачи рассматривается randomизированная схема имитации отжига. Локальные геометрические свойства минимизирующих ошибку обучающих траекторий в фазовом пространстве сети предложено использовать для управления динамикой температуры.

Таблица 3

Представление кусочно-линейной функции
нейронной сетью

	$p = 4$	$p = 10$	$p = 16$	$p = 25$	$p = 40$
$\eta(N = 4)$	4.0	1.5	1.3	1.16	1.23
$\eta(N = 10)$	29	4.5	1.6	1.7	1.4
$\eta(N = 16)$	44	2.0	2.3	1.7	1.4
$\eta(N = 25)$	48	2.0	1.8	1.5	1.1
$\eta(N = 40)$	57	2.4	2.2	2.1	1.5
η_s	744	6.4	1.6	2.5	1.4

Обнаружено, что многослойный персепtron демонстрирует способность к обучению при значительном (вплоть до нескольких порядков) понижении интегральной активности синапсов, что делает эту нейросеть весьма перспективной для аппаратных реализаций.

Проведено также сравнение ошибки обучения и обобщения для задач прогноза временных рядов на примере логистической функции и линейно-конгруэнтного датчика случайных чисел. В последнем случае нейронная сеть имеет преимущество перед методами гладкой интерполяции.

2. КОМПЬЮТЕРНЫЙ КОД PERCY И ПРИЛОЖЕНИЯ

2.1. Описание программы Percy

Рассмотренная в первой части работы нейросетевая архитектура и схема обучения реализованы * в комплексе программ Percy для персональных ЭВМ класса IBM PC.

Комплекс включает в себя следующие модули:

- Модуль исходной информации. он представляет собой интерпретатор со специализированного языка начальных данных. Функцией модуля является подготовка рабочих структур данных для остальных модулей;
- Модуль базы данных. Функциями этого модуля являются операции с базами данных для обучающих выборок, а также тестовых данных и результатов распознавания;
- Модуль обучения. В нем реализована описанная рандомизированная схема обучения. Модуль имеет возможность для сбора диагностической информации о процессе обучения. Блок адаптивного управления температурой находится в стадии разработки;
- Модуль распознавания. Выполняет моделирование процесса распознавания обученной искусственной нейронной сетью. Результаты распознавания помещаются в текстовый файл и базу данных.

Все программы написаны на языке TURBO PASCAL в среде MS DOS. Представленные в первой части работы результаты выполнены с применением методической версии комплекса Percy для системы MATLAB (система MATLAB разработана фирмой Math Works, Inc.).

Ниже будут представлены некоторые прикладные задачи, поставленные на основе принципов кибернетического моделирования. Для них предлагаются решения с использованием комплекса Percy.

* В программную реализацию большой вклад внес С.И.Самарин

2.2. Кибернетическая модель магнитной кумуляции

Явление магнитной кумуляции [12, 24] состоит в возрастании плотности энергии магнитного поля при сжатии магнитного потока проводящей оболочкой.

Рассмотрим задачу в следующей постановке. Начальное затравочное аксиальное магнитное поле напряженности H_0 , которой соответствует плотность энергии $E_{M0} = H_0^2/8\pi$, находится внутри проводящей цилиндрической оболочки с аспектным отношением a_0 (a_0 — отношение внутреннего радиуса оболочки к ее внешнему радиусу). Внешняя часть оболочки испаряется тепловым излучением драйвера с плотностью энергии E_D , в качестве которого может быть использован мощный лазер или лабораторный источник мягкого рентгена. Оставшаяся неиспаренной масса оболочки ускоряется к оси, сжимая магнитное поле. В случае идеальной проводимости захваченный магнитный поток сохраняется, что приводит к росту напряженности поля. Под действием давления магнитного поля оболочка тормозится вплоть до остановки и разворота на минимальном радиусе. При этом достигается максимальное значение напряженности поля, плотность энергии драйвера E_D , т.е. происходит кумуляция плотности энергии.

Таблица 4

Исходные данные для построения
кибернетической модели магнитной кумуляции

E_{M0}/E_D	a_0	E_M/E_D
$4.65 \cdot 10^{-3}$	0.98	1.75
$4.65 \cdot 10^{-3}$	0.95	13.4
$4.65 \cdot 10^{-3}$	0.92	39.4
$4.65 \cdot 10^{-3}$	0.90	34.1
$4.65 \cdot 10^{-5}$	0.98	0.75
$4.65 \cdot 10^{-5}$	0.95	51.9
$4.65 \cdot 10^{-5}$	0.90	21.9
$4.65 \cdot 10^{-3}$	0.93	41.1
$4.19 \cdot 10^{-4}$	0.93	73.9
$4.65 \cdot 10^{-5}$	0.93	79.9
$4.19 \cdot 10^{-6}$	0.93	24.1
$4.65 \cdot 10^{-7}$	0.93	3.49
$1.86 \cdot 10^{-4}$	0.93	82.6

Простой вариант нейросетевой модели явления (он и рассмотрен в данной работе) включает в качестве исходных данных введенные параметры E_{M0}/E_D и a_0 , а предсказываемым системой параметром является

коэффициент передачи энергии от драйвера к полю E_M/E_D . Более общие модели могут включать также среди параметров массу и вещества оболочки, динамические характеристики драйвера, коэффициент удержания потока при неидеальной проводимости и другие величины.

Обучающая выборка для нейросетевой модели PERCY была получена из результатов математического моделирования магнитной кумуляции в приближении магнитной газовой динамики. Значения безразмерных параметров приведены в табл.4.

Характерной особенностью данных является резкая резонансная зависимость степени кумуляции от аспектного отношения. Кибернетическая нейросетевая модель может быть использована для планирования дальнейших вычислительных экспериментов, с целью поиска режима с максимальной кумуляцией. Нейронная сеть, построенная поданным табл.4, предсказывает значение пика кумуляции при $a_0 = 0.94$ с $E_{M0}/E_D = -1.86 \cdot 10^{-4}$. Полученное в этой точке методом математического моделирования значение составило $E_M/E_D = 96.2$.

Форма поверхности модели по данным табл.4 и линии уровня в плоскости параметров "затравочное поле — аспектное отношение" приведены на рис.6.

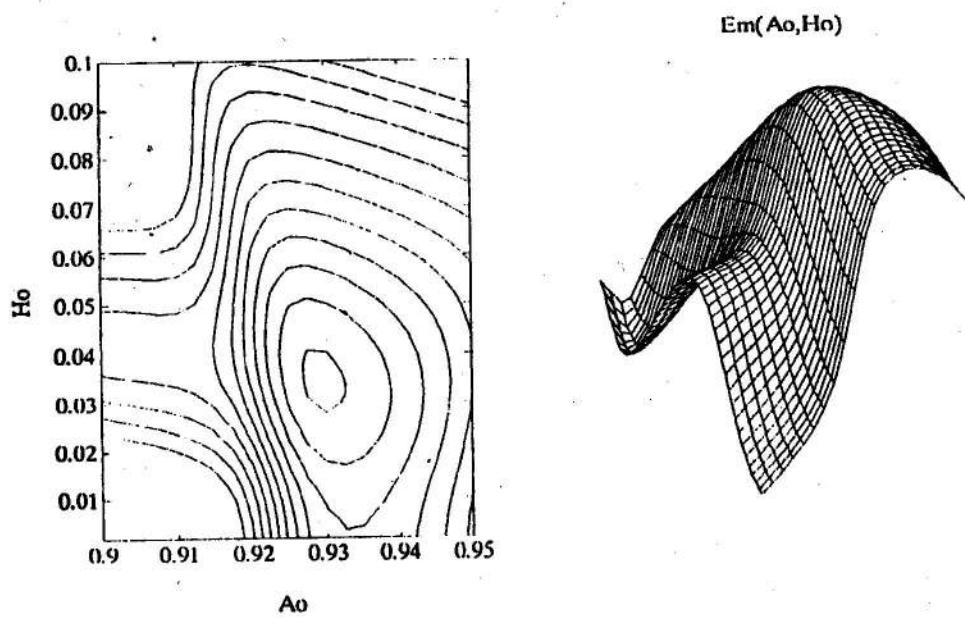


Рис. 6. Форма поверхности и линии уровня для нейросетевой модели магнитной кумуляции.

Вновь полученное значение далее может быть использовано для получения более точной модели.

Важной чертой нейросетевой кибернетической модели является воз-

можность использования для ее построения первичных экспериментальных (или расчетных) данных, а также то, что вычисления, проводимые при помощи обученной нейронной сети, выполняются практически мгновенно. Кибернетические модели физических явлений на основе нейросетевых систем могут эффективно использоваться для систематизации экспериментальных и теоретических данных, решения задач оптимизации и выявления "скрытых" множественных связей между параметрами.

Важным применением является использование кибернетической модели для планирования эксперимента.

Ниже будет рассмотрено другое применение нейронной сети — диагностическая задача классификации.

2.3. Кибернетическая модель диагностики неисправностей в системе охлаждения реактора АЭС

Проблема автоматического анализа и поддержки принятия решений в случае нештатных ситуаций на АЭС является крайне актуальной. Во время инцидента число диагностических сигналов может достигать нескольких сотен в минуту. Современные нейросетевые системы способны справляться с управлением отдельными блоками систем безопасности АЭС в режиме реального времени [11, 25]. В силу большой важности исследований в этом направлении авторы настоящей статьи сочли возможным воспроизвести некоторые результаты модели [11] на основе разработанной системы PERCY.

В цитируемой работе [11] рассмотрена кибернетическая модель комплекса диагностики насоса системы водяного охлаждения реактора. В качестве входных параметров модель включает в себя показания 12 аварийных датчиков. Выходными показателями являются 9 основных локальных неисправностей в системе, вызывающих срабатывание аварийных сигналов. Среди них превышение температуры и давления в различных компонентах системы, нарушения блокировки, недостаточное поступление охладителя и другие.

Особенностью системы является возможность возникновения аварийных сигналов одновременно на нескольких датчиках, а также взаимное влияние различных неисправностей. Задачу классификации аварийных ситуаций осложняет потенциальная возможность отказов некоторых датчиков. База данных, на которой проводилось обучение нейросетевой модели, приведена в [11]. Она получена на основе формальной схемы системы охлаждения, в которой исходными являются неисправности, а результатами — показания датчиков. Нейросетевая система, таким образом, обучалась решению обратной задачи — классификации неисправностей по показаниям датчиков — на основе данных прямой задачи.

Авторами цитируемой работы был использован персептрон 12-8-9 с обучением на основе обратного распространения ошибок. Приемлемое обучение было достигнуто за 5875 итераций. Заметим, что использованная нейронная сеть имеет 176 параметров, в то время как объем обучающей выборки составлял 41 образ. Такая ситуация должна приводить к высокой ошибке обобщения, что и было обнаружено в [11]. Тем не менее, полученная нейросетевая модель успешно проявила себя на тестовых образах, при классификации по неполной информации из-за отказа некоторых датчиков, при классификации нескольких одновременно возникших неисправностей, а также при анализе картинки показаний датчиков, меняющейся во времени. Последнее возникает, например, при колебаниях температуры вблизи аварийного порогового значения.

Целью наших исследований в этой части было получение обученного состояния нейронной сети в рандомизированной схеме на имеющейся базе данных и подтверждение основных результатов цитируемой работы.

Достигнутый авторами [11] уровень ошибки обучения в методе обратного распространения слабо зависит от объема скрытого слоя в пределах от 4 до 24 нейронов. Поэтому мы выполнили расчеты с 4-мя нейронами, так это предпочтительнее с точки зрения уменьшения ошибки обобщения.

Требуемое обучение после подбора изменения температуры в схеме имитации отжига было достигнуто за 200 историй (шагов Монте-Карло на синапс), что подтверждает работоспособность выбранного метода обучения.

ЗАКЛЮЧЕНИЕ

Остановимся на основных итогах работы.

1. Рассмотрена топология многослойной нейронной сети и описана рандомизированная схема ее обучения. Схема является общей для всех сетей данной архитектуры. Данная модель реализована в комплексе программ PERCY.

2. Рассмотрены геометрические характеристики обучающих траекторий и показан их фрактальный характер. Предложены феноменологические параметры — локальная фрактальная размерность траектории, среднеквадратичное изменение энергии принятых и отвергнутых шагов в схеме испытаний Метрополиса, поведение которых в процессе обучения может быть использовано для адаптивного управления температурой. Исследования авторов в этом направлении продолжаются.

3. Изучена ошибка обобщения многослойной сети. Для задач прогноза временных рядов показано, что в случае негладкой порождающей хаотический процесс функции нейронная сеть значительно превосходит по качеству прогноза алгоритмы интерполяции при равном числе свобод-

ных параметров. Предложены удобные для практического использования скейлинговые связи между ошибками обучения и обобщения.

4. Предложена и исследована в компьютерных экспериментах нейросетевая кибернетическая модель явления магнитной кумуляции, а также модель классификатора отказов в системе охлаждения реактора АЭС. Аналогичные модели могут найти широкое применение для обобщения, экспериментальных и теоретических расчетных данных, оптимизации и планировании эксперимента.

Автор выражает благодарность В.А.Лыкову за полезные обсуждения, С.И.Самарину за помощь в разработке программы PERCY, а также Яну Ларсену за предоставленные препринты центра CONNECT и плодотворную дискуссию во время осеннего семинара 1993 г. в Нижнем Новгороде.

ЛИТЕРАТУРА

1. Бассерман Ф. Нейрокомпьютерная техника. — М.: Мир, 1992.
2. Kirkpatrick S., Gelatt C.D. Jr., Vecchi M.P. // Science. 1983. V.220. P.671.
3. Watkin T.L.H. // Rev.Mod.Phys. 1993. V.65. N 2. P.499.
4. Terekhoff S.A. // Pattern Recognition and Image Analysis. 1992. V.2. N 4. P.445.
5. Terekhoff S.A. // Proceedings of RNNS/IEEE Symposium on Neuroinformatics and Neurocomputing, Rostov-on-Don, Russian Federation, 7–10 october, 1992. V.1. P.457.
6. Розенблatt Ф. Принципы нейродинамики. — М.: Мир, 1965.
7. Hertz J.A., Thorbergson G.L., Krogh A. // NORDITA preprint 88/20. 1988.
8. Diyankov O.V., Samarin S.I., Terekhoff S.A. // Pattern Recognition and Image Analysis. 1992. V.2. N 2. P.139.
9. Rybak I.A., Golovan A.A., Gusakova V.I. et al. // Neural Networks World. 1991. V.4. P.245.
10. Bellustin N.S., Kuznetsov S.O., Nuidel I.V., Yakhno V.G. // Neurocomputing. 1991. V.3. P.231.
11. Se Woo Cheon, Soon Heung Chang, Hak Yeong Chung and Zeung Nam Bien. // IEEE Transactions on Nuclear Science. 1993. V.40. N 1. P.11.
12. Сахаров А.Д., Людаев Р.З., Смирнов Е.Н. и др. // ДАН СССР. 1965. Т.165. N 1. С.65.
13. Лоскутов А.Ю., Михайлов А.С. Введение в синергетику. — М.: Наука, 1990.
14. Тараксо М.З. // Препринт N 165. — ФЭИ: Обнинск, 1969.
15. Rumelhart D.E., Hinton G.E., Williams R.J. // Nature. 1986. V.323. N 9. P.333.

16. Alexander S., Bernasconi J., Schneider W.R., Orbach R. // Rev.Mod.Phys. 1981. V.53. P.175.
17. Терехов С.А. // Препринт N 21. — ВНИИТФ, 1992.
18. Самарин С.И., Терехов С.А. // Тез.докладов симпозиума "Физические принципы и методы оптической обработки информации", Гродно 1993.
19. Morgenstern I. // Z.Phys.B — Condensed Matter. 1987. V.67. P.265.
20. Svarer C., Hansen L.K., Larsen J. // CONNECT preprint, 1992.
21. Larsen J. // CONNECT preprint, 1992.
22. Diyankov O.V., Lykov V.A. and Terekhoff S.A. // Proceeding of RNNS/IEEE Symposium on Neuroinformatics and Neurocomputing, Rostov-on-Don, Russian Federation, 7-10 October. 1992. V.2. P.829.
23. Форсайд Дж., Малькольс М., Моулер К. Математические методы математических вычислений. — М.: Мир, 1980.
24. Fowler C.M., Garn W.B., Caird R.S. // J.Appl.Phys. 1960. V.31. P.588.
25. Turkcan E., Ciftcioglu J., Nabeshima K. // Nucl.Europe Worldscan. 1993. N 11/12. P.31.

Российский федеральный
ядерный центр — Всероссийский
НИИ технической физики,
г.Снежинск

Поступила в редакцию
23 мая 1994 г.

**MULTILAYRED NEURAL NETWORK
WITH RANDOMIZED LEARNING:
A MODEL AND APPLICATIONS**

S.A. Terekhov

This paper is devoted to the simulated annealing technique in randomized approach for multilayered neural network learning. Fractal properties of learning trajectories in the phase space are investigated. External annealing control on the base of phenomenologic trajectory properties is proposed. The comparison of the generalization error in the multilayred perceptron and in the method of splines for time series prognosis is carried out. It is shown that for rough series generating functions neural network works better than splines with the same number of parameters.

Developed scheme is applied to build the cybernetic model of the magnetic implosion phenomena, and also for fault classification in the nuclear power plant reactor coolant system.