

УДК 542.34

ИСПОЛЬЗОВАНИЕ НЕЙРОСЕТЕВЫХ СТРУКТУР СВОБОДНОЙ ДИНАМИКИ С КОНТЕКСТНО-ЗАВИСИМЫМИ ПАРАМЕТРАМИ ДЛЯ НАБЛЮДЕНИЯ В НЕОДНОРОДНЫХ НЕСТАЦИОНАРНЫХ СРЕДАХ

А. Г. Хоботов, А. И. Хилько, В. И. Романова

Институт прикладной физики РАН, г. Нижний Новгород, Россия

Обсуждается классификация нейронных сетей по их динамике. Приводятся результаты численного анализа возможностей использования нейроноподобных структур свободной динамики с контекстно-зависимыми параметрами для реализации адаптивного наблюдения в сложных нестационарных средах. Анализируется эффективность решения указанных задач такими нейроноподобными структурами в сравнении с традиционными методами.

ВВЕДЕНИЕ

При обработке информации широкие перспективы имеет использование различных нейроноподобных сетей [1–3], позволяющих выявлять достаточно сложные зависимости во входном информационном потоке. Эти возможности используются для решения задач кластеризации, распознавания образов, устранения избыточности представления информации при архивации данных, а также для построения прогнозирующих систем, что позволяет решать широкий круг практических задач при ограниченной априорной информации, когда необходимо использовать методы адаптации и самообучения [4, 5]. Применяемые в настоящее время при решении таких задач нейронные сети можно классифицировать как сети с принудительной динамикой, которая определена топологией сети и правилами модификации весов нейронных связей. Большой научный и практический интерес вызывают и сети другого типа, а именно нейронные структуры со свободной динамикой, поведение которых определяется такими их характеристиками, как вид и параметры пороговых функций, а также функции связи. Особый интерес вызывают такие сети, в которых указанные функции зависят от характера возбуждения [6–10].

Для изучения поведения нейронных сетей активно используются методы нейродинамики, в которых нейронные ансамбли описываются системами нелинейных уравнений [5, 11]. Использование таких систем в качестве моделей ансамблей нейронов мозга демонстрирует возможность возникновения пространственно-временных динамических структур, отвечающих рождению крупномасштабных одночастотных колебаний [6–9], а также синхронизацию волн, которая сохраняется и после прекращения внешнего стимулирования [6–9, 12].

Результаты моделирования и экспериментов позволяют предположить, что собственная пространственно-временная динамика нейронных ансамблей ответственна за ощущения, испытываемые человеком во время сна, когда внешнее стимулирование коры практически отсутствует [13–17]. Однако поскольку возникающие во сне образы обычно имеют достаточно упорядоченную структуру, можно предположить, что нейронные ансамбли в коре головного мозга не являются однородными и однородно-связанными [6, 13, 17]. Изучение динамических механизмов краткосрочной памяти человека показывает, что информация может храниться мозгом до сотен секунд [6, 14–17]. Один из предложенных динамических механизмов формирования такой памяти заключается в реализации кластеров нейронной активности, существование которых обусловлено

особым свойством некоторых нейронов головного мозга — последеполяризацией, т. е. увеличением возбудимости их мембран после генерации потенциала действия.

В данной работе анализируются возможности выполнения с помощью нейроноподобных структур свободной динамики с контекстно-зависимыми параметрами операций адаптивного наблюдения в неоднородных нестационарных средах. В частности, исследуются возможности выполнения операций регуляризирующей предварительной обработки сложных информационных распределений, а также процедур сравнения, классификации и принятия решений при зондировании океанических волноводов акустическими сложно модулированными импульсными сигналами [18–24].

1. НЕЙРОНОПОДОБНЫЕ СТРУКТУРЫ СВОБОДНОЙ ДИНАМИКИ С КОНТЕКСТНО-ЗАВИСИМЫМИ ПАРАМЕТРАМИ

В отличие от сетей с принудительной динамикой, нейроноподобные системы свободной динамики предполагают, что веса связей распределяются по некоторому закону, оставаясь постоянными во время функционирования сети [6–9]. Для описания динамики такого рода нейронных сетей используются интегро-дифференциальные уравнения, имеющие следующую структуру [6–8]:

$$\tilde{U}(\mathbf{r}, t) = \int_{-\infty}^t \int_{-\infty}^{+\infty} F_0[U(\mathbf{r}', t')] \Phi(\mathbf{r}, \mathbf{r}') \exp[-\delta(t - t')] d\mathbf{r}' dt'. \quad (1)$$

Здесь $\mathbf{r}$ и $\mathbf{r}'$ — радиус-векторы в n -мерном пространстве, характеризующие нейроноподобные элементы в моменты времени t и t' соответственно (для удобства анализа дискретное пространство элементов сети заменено на непрерывное пространство, при этом используется непрерывная величина $\mathbf{r}$, каждое значение которой фактически обозначает индекс отдельного нейрона). Величина $U(\mathbf{r}', t')$ характеризует уровень и пространственно-временную структуру активации нейроноподобного элемента, а величина $\tilde{U}(\mathbf{r}, t)$ — пространственно-временной отклик системы на активацию сети. Вид отклика $\tilde{U}(\mathbf{r}, t)$ определяется в первую очередь структурой нейронов, которая характеризуется пороговой функцией F_0 , меняющейся в диапазоне значений $[0, 1]$, а также функцией связей нейронов $\Phi(\mathbf{r}, \mathbf{r}')$, которая, в общем случае, описывает и процесс диссипации. Выражение $\exp[-\delta(t - t')]$ определяет весовую функцию памяти, в которой после подбора масштаба времени можно полагать $\delta = 1$.

Структура нейронных сетей типа (1) характеризуется прежде всего зависимостью пороговой функции от уровня активации $F_0[U(\mathbf{r}', t')]$, т. е. от контекста. Поскольку элементы сети связаны, то их активация вызывает формирование пространственно-временных структур, имеющих сложную динамику. Условием стационарной динамики описываемой уравнениями (1) нейронной среды является монотонность пороговой функции и взаимность однородной и изотропной функции связи [7, 8]. При выполнении этих условий, после некоторого переходного процесса нейронная среда принимает стационарное динамическое состояние. Режимы стационарного состояния диссипативной динамической нейроноподобной системы являются аттракторы [24, 25]. Это могут быть регулярные аттракторы: неподвижные точки (устойчивые состояния равновесия), предельные циклы (устойчивые периодические движения), а также торы (квазипериодические колебания). При несоблюдении этих условий динамика сети имеет более сложный немонотонный характер, при котором могут формироваться и странные хаотические аттракторы (режимы детерминированного хаоса), траектории которых являются непериодическими и не замыкаются на типичных интервалах наблюдения. Кроме того, наблюдаются режимы функционирования с экспоненциальной неустойчивостью, при которых малые отклонения от первоначального режима нарастают.

Динамика рассматриваемых систем характеризуется величиной энтропии Колмогорова—Синая (КС-энтропии) H^{ks} [26–29]. В частности, если динамика системы является периодической (предельный цикл) или квазипериодической (тор), то с течением времени расстояние между траекториями изначально близких точек в фазовом пространстве $d(t)$ не возрастает и КС-энтропия равна нулю ($H^{ks} = 0$). При наличии в системе устойчивой неподвижной точки $d(t) \rightarrow 0$ и $H^{ks} = 0$. В случае хаотической динамики КС-энтропия больше нуля ($H^{ks} > 0$). Энтропия Колмогорова—Синая — максимальный из характеристических показателей Ляпунова, поэтому она позволяет судить о скорости, с которой утрачивается информация о начальном состоянии системы. Таким образом, для сети, динамика которой характеризуется нулевым значением КС-энтропии, возможно представление и хранение информации в динамической форме. Динамическая форма характеризуется тем, что в сети формируются сложные колебательные процессы, которые могут быть стационарными при компенсации диссипации внешними источниками. Возможность существования таких режимов в нейроноподобных средах обсуждалась в ряде исследований, например, в [8, 9].

В моделях нейронных сетей, построенных на основе известных парадигм (см., например, [1, 2, 11]), модификация параметров сетей, в частности весовых коэффициентов, происходит по жёстким вполне определённым правилам на этапе настройки (обучения) сети. В конечном счёте, этим механизмом во многом и определяется динамика таких сетей. В нейронных структурах естественного происхождения сложно проследить наличие такого механизма. Тем не менее, некоторый механизм модификации значений параметров должен существовать. Мы можем предположить, что модификация значений этих параметров происходит в зависимости от данных, поступающих на вход сети.

Можно допустить, что с процедурной точки зрения мозг выполняет всего несколько функциональных операций: запоминание, хранение, извлечение (вспоминание) и узнавание (сопоставление). Возможность реализации таких операций на нейроноподобных структурах можно продемонстрировать, если в качестве структуры для моделирования таких операций выбрать нейронную структуру, основными элементами которой являются нейроны, описываемые моделью МакКаллока—Питтса (см., например, [5]). Если допустить наличие сложных динамических режимов в естественных нейронных структурах (см., например, [30]), то можно с достаточной степенью обоснованности предположить, что в них возможна и обсуждаемая «сигнальная» форма хранения информации. В этом случае на основе операции, сходной с операцией дизъюнкции, может быть сформирован некоторый обобщённый сигнал, представляющий информационное содержание когнитивной системы. Операция конъюнкции в этом случае используется для отождествления сигнала на входе когнитивной системы с одним из сигналов, составляющих обобщённый сигнал.

Нейросетевые структуры, рассматриваемые далее в данном исследовании, являются разновидностью сетей свободной динамики, особенность которых заключается в том, что их характеристики (параметры и функции связи, а также пороговые функции) определяются контекстом входных сигналов. В рамках существующей системы классификации такие сети являются однослойными синхронными многосвязными сетями (сети с наличием обратных связей), гетерогенными по параметрам функций связи и активации.

В качестве базового уравнения, описывающего свободную динамику нейронных сетей с контекстно-зависимыми параметрами (далее, КЗ-сетей), будем рассматривать уравнения, аналогичные тем, что рассматривались в [8]. Но, в отличие от [8], будем считать, что потери (или параметры динамической памяти системы) отсутствуют, а пороговая функция зависит от вида функции связи элементов сети, которая, в свою очередь, определяется уровнями активации в связанных нейронных элементах $\Phi[\mathbf{r}, \mathbf{r}', U(\mathbf{r}', t), U(\mathbf{r}, t)]$ [10, 21]. За счёт связи элементов пороговая функция

T будет также зависеть от уровня активации во всех связанных точках $T[U(\mathbf{r}', t), U(\mathbf{r}, t)]$. Таким образом, состояние такой нейроноподобной КЗ-системы (отклик на активацию) с учётом (1) можно описывать уравнением

$$\tilde{U}(\mathbf{r}, t) = \int_{-\infty}^t \int_{-\infty}^{+\infty} F_0[\Phi[\mathbf{r}, \mathbf{r}', U(\mathbf{r}', t'), U(\mathbf{r}, t')], T[U(\mathbf{r}', t'), U(\mathbf{r}, t')]] \varphi(t, t') d\mathbf{r}' dt' + U(\mathbf{r}, 0), \quad (2)$$

где $\varphi(t, t') = \exp[-\delta(t - t')]$ — функция динамической памяти сети.

Для численного анализа рассмотрим далее КЗ-сети типа (2) с уточнёнными зависимостями пороговой функции от контекста:

$$\tilde{U}(\mathbf{r}, t) = U(\mathbf{r}, 0) + \int_{-\infty}^t \int_{-\infty}^{+\infty} F_0(\Phi\{\eta(\mathbf{r} - \mathbf{r}'), U(\mathbf{r}', t'), U(\mathbf{r}, t'), \mu[U(\mathbf{r}', t'), U(\mathbf{r}, t')], \alpha[U(\mathbf{r}', t'), U(\mathbf{r}, t')], \beta[U(\mathbf{r}', t'), U(\mathbf{r}, t')]\}) \varphi(t, t') d\mathbf{r}' dt', \quad (3)$$

где функции η и μ определяют правило изменения функции связи элементов сети в зависимости от контекста (функции активации). Функции α и β задают правило изменения пороговой функции в зависимости от уровня активации. Из вида (3) следует, что степень и характер воздействия входной функции активации нейронной сети (контекста) на структуру КЗ-сети может регулироваться путём изменения функций α , β , η и μ . Вид этих функций должен быть выбран так, чтобы отклик системы обеспечивал выполнение исходно заданных требований, направленных на решение определённых конкретных задач, например, на усиление или подавление реакций на определённый тип воздействия. При этом можно говорить о задачах синтеза описываемых уравнением (3) сетей, оптимальных для решения конкретных задач. Такой синтез заключается в выборе структуры сети, т. е. вида и параметров функций F_0 и Φ .

В приложении к задаче наблюдения в нестационарных неоднородных средах индекс нейроноподобного элемента соответствует расположенным в точках $\mathbf{r}$ сенсорам распределённой в среде системы наблюдения. При этом размер сети $P(\mathbf{r})$ является приёмной апертурой мультистатистической системы наблюдения [18–24]. При достаточной связанности элементов сети эта функция будет определять предельную эффективность реакции сети (предельные чувствительность и разрешение), что будет соответствовать когерентному сложению парциальных сигналов при принятии интегрального решения (формирование отклика всей КЗ-сети).

При наблюдении в природных волноводах естественными ограничениями являются утрата информации об объекте при распространении сигналов до приёмных апертур [18]. Кроме того, потеря информации о наблюдаемом объекте вызвана и конечной чувствительностью сенсоров, определяемой сторонними и собственными шумами, а также ограниченностью размеров приёмных апертур. Для реализации предельно эффективной сети, соответствующей когерентному накоплению откликов отдельных сенсоров (нейронов), требуется существенная информация об объекте и помехах [18, 19]. Ограниченность априорной информации приводит к необходимости настройки сети так, чтобы ширина функции связи нейронных элементов была уже входной апертуры мультистатистической системы наблюдения, т. е. $\Delta\Phi(\mathbf{r}, \mathbf{r}') < P(\mathbf{r})$. При этом ширина функции связи $\Delta\Phi(\mathbf{r}, \mathbf{r}')$ должна выбираться на основе данных о когерентности (связанности) принимаемых сенсорами входных сигналов и шумов (для отвлечённой нейроноподобной среды — внешних возбуждающих нейронную систему воздействий). В общем случае сигналы и шумы характеризуются пространственной и временной изменчивостью статистических распределений, что предполагает адаптацию структуры функции связи к такой изменчивости [24, 31–33].

В силу нелинейности КЗ-сетей их аналитическое исследование затруднено, однако возможно их изучение на основе методов численного моделирования. Структура используемых далее функций F_0 и Φ выбиралась с учётом предварительных численных экспериментов с такого рода сетями, анализа поведения систем с открытой динамикой, а также на основе результатов исследований работы мозга животных и человека [6–10, 12, 15–22, 25]. В частности, при численных экспериментах, результаты которых будут обсуждаться ниже, полагалось, что динамическая память отсутствовала: $F_0(\Phi, \alpha, \beta) = \{1 + \exp[-\beta(\Phi + \alpha)]\}^{-1}$, где $\alpha = U(\mathbf{r}, t) - U(\mathbf{r}', t)$, $\beta = U(\mathbf{r}, t)/U(\mathbf{r}', t)$, $\Phi(\eta, x, y, \mu) = (y + x\eta^2) \exp(-\mu\eta^2)$, $\eta = |\mathbf{r} - \mathbf{r}'|$, $x = U(\mathbf{r}, t)$, $y = U(\mathbf{r}', t)$. Ширина области интегрирования и Δt являются параметрами управления динамикой сети. Их значения при выполнении конкретных расчётов подбирались из структуры конечных состояний сети, а также откликов сети, которые анализировались с учётом априорных требований, определяемых особенностями решаемых задач.

2. ИСПОЛЬЗОВАНИЕ НЕЙРОНОПОДОБНЫХ КЗ-СИСТЕМ ДЛЯ АДАПТИВНОГО НАБЛЮДЕНИЯ

Распознавание образов, поступающих от многоэлементных сенсорных систем (например, от совокупности чувствительных элементов в сетчатке глаза) является одной из основных и важнейших для жизнедеятельности человека процедур, выполняемых мозгом [18–24]. Такую процедуру можно интерпретировать как операцию проверки гипотез, формируемых на основе информации, хранящейся в памяти в виде многопараметрических моделей (образов). Аналогичную задачу должны решать и мультистатистические интегрированные сенсорные системы, наблюдающие объекты в неоднородной нестационарной среде. Алгоритмически, распознавание можно интерпретировать как отыскание решений в виде совокупности оценок истинных значений параметров моделей, соответствующих наблюдаемым объектам. В качестве окончательного принимается то решение, при котором значение решающей статистики удовлетворяет заданным статистическим критериям. Такая процедура обеспечивает решение обратных задач наблюдения, реализуемого искусственными системами видения и лоцирования, которые можно рассматривать в некотором смысле как стимуляторы работы мозга человека [10, 12, 19, 21].

Особенностью большинства практических задач наблюдения является очень большой динамический диапазон пространственных и временных вариаций измеряемых сигналов и шумов, а также изменчивость их статистических характеристик. Часто уже существующие системы наблюдения (симуляторы наблюдения), реализованные в виде технических устройств, имеют заранее заданные решающие статистики и пороговые значения, что существенно ограничивает их эффективность в условиях, когда сигналы и шумы являются нестационарными [18–24, 31–33]. Аналогичными свойствами обладают и нейроноподобные среды с принудительной динамикой, которые, по существу, выполняют функции согласованных фильтров с заданными параметрами. Однако при мультистатистическом наблюдении в нестационарных неоднородных средах, например, в природных волноводах, необходимо, чтобы решающие статистики и пороговые значения были адаптивными [10, 21, 22].

С этой целью следует использовать априорную информацию о полезных сигналах и шумах, а также о состоянии среды и сенсорных систем. При этом многоэлементная интегрированная система наблюдения может строиться как адаптивная нейроноподобная среда, обладающая возможностью получения и использования указанной априорной информации, в том числе из принимаемых сигналов и шумов на этапе предварительной обработки [19, 21, 22]. Адаптивные алгоритмы такой нейроноподобной среды должны обеспечить оптимальный выбор структуры решающих статистик и пороговых значений как для отдельных сенсоров, так и для некоторой совокупно-

сти сенсоров, формирующей траектории перебора гипотез при поиске решения. Важно отметить, что в практических условиях чаще всего объём априорной информации ограничен, что вызывает необходимость поиска решений в условиях недостоверных данных. Используемые в таких случаях детерминированные решающие правила являются неустойчивыми и достоверных решений часто получить не удаётся, т. е. «система наблюдения не видит». Нейроподобные КЗ-системы способны преодолеть указанные трудности.

В частности, КЗ-системы позволяют выполнять адаптацию к контексту для двух важнейших этапов наблюдения. На первом этапе предварительной обработки измеряемых данных адаптация позволяет не только оптимизировать динамический диапазон входного потока данных, но и выделить наиболее достоверные данные, что обеспечивает регуляризацию при наблюдении. На втором этапе при выполнении операции сравнения нейроподобные КЗ-системы позволяют существенно повысить устойчивость и точность сравнения, поскольку они способны в зависимости от контекста, т. е. адаптивно, менять как решающие правила, так и пороговые значения. Для мультистатистических систем наблюдения такая обработка может обеспечить и адаптацию на основе априорной информации о среде, наблюдаемом объекте и шумах в виде параметрических моделей.

Технически такая адаптация сводится к пространственной фокусировке и частотной фильтрации. Операции сравнения выполняются уже после предварительной обработки, что можно интерпретировать как оптимальную (адаптивную) нормировку измеряемых данных, и формально эти операции можно включить в решающую статистику. Такие решающие статистики обеспечивают не только максимальную чувствительность алгоритмов наблюдения, но и их устойчивость.

На рис. 1. показаны результаты нелинейной предварительной обработки (эквализации контраста) двумерного распределения данных от системы сенсоров $U(\mathbf{r}, t = t_0) = U(x, y, t = t_0)$, полученные с помощью нейроподобной КЗ-сети (3). Далее двумерное распределение данных от системы сенсоров будем называть изображением. Особенностью исходного изображения (рис. 1а, верхняя панель) является наличие существенной неоднородности среднего уровня по полю. Это ограничивает возможности принятия решения при оценке параметров распределённых по всему полю наблюдения деталей с промежуточными масштабами. На рис. 1а (нижняя панель) показана гистограмма распределения амплитуды сигналов в изображении. Одновременная оценка значений параметров деталей с промежуточными масштабами в области с низкими усреднёнными уровнями в распределении и в областях с высоким средним уровнем сигналов с использованием фиксированного порогового значения оказывается невозможной.

Решение такой и многих подобных задач возможно с использованием контекстно-зависимой нелинейной обработки данных, в частности, контекстного выбора значений пороговых уровней, адаптивных к среднему уровню сигнала в локальной зоне, т. е. выбор значений в зависимости от наблюдаемых данных. Примером выполнения такого рода процедур с помощью нейронной сети (3) является выравнивание контраста изображения при нормированном значении $\Delta t = 1$ (рис. 1б). На этом изображении видно, что за счёт выравнивания среднего уровня во входном распределении параметры деталей с промежуточными масштабами могут быть с одинаковой эффективностью оценены уже в пределах всего неоднородного поля зрения мультистатистической системы наблюдения. Важно отметить, что, в отличие от случая линейной фильтрации, другие детали изображения, например, резкие вариации средних уровней измеряемых сигналов, не теряются. Результат преобразования исходного изображения с обратным временем, когда $k = -1$ и осуществляется процедура подавления деталей с мелкими масштабами, показан на рис. 1в.

Для оценки эффективности преобразований можно использовать численные характеристики количества информации $I[\ln(\tilde{U}), U] = H[\ln(\tilde{U})] - H(U)$, характеризующие изменения шенноновской энтропии гистограммы распределения амплитуды. Здесь $H[\ln(\tilde{U})]$ — энтропия гистограммы




Рис. 1. Реализация с помощью нейроноподобной сети (3) процедуры выравнивания контраста двумерного изображения из $2,0 \cdot 10^2 \times 2,5 \cdot 10^2$ значений величин U . На панели (а) представлены исходное изображение и гистограмма распределения амплитуды соответственно, на панели (б) — результат выравнивания, $I[\ln(\tilde{U}), U] = 0,753$, на панели (в) — преобразование с обратным временем, $I[\ln(\tilde{U}), U] = -0,553$. Параметр $\mu = 10^{-2}$, нормированное значение $\Delta t = 0,1$ для (б) и $\Delta t = -0,1$ для (в)

преобразованного изображения, $H(U)$ — энтропия гистограммы исходного изображения. Как следует из приведённых на рис. 1 и других результатов, после обработки с помощью КЗ-сети на изображениях появляются амплитудные отсчёты, которые обеспечивают усиление контраста исходно слабоконтрастных мелкомасштабных элементов изображения (см. рис. 1б). При этом $I[\ln(\tilde{U}), U] > 0$. При изменении знака времени в уравнении (3) в результате обработки получают изображения (см. рис. 1в), характеризующиеся отрицательным значением $I[\ln(\tilde{U}), U] < 0$. В этом случае на изображении ослабляются слабоконтрастные участки, которые при решении ряда конкретных практических задач можно считать шумом. Эта процедура может отчасти объяснить механизм, лежащий в основе формирования сокадного движения зрачка при осмотре человеком изображения, когда зрачок движется по точкам максимального контраста.

Отметим также, что размер области интегрирования, который определяется функцией связи, может существенно повлиять на результаты обработки изображения. Примером, иллюстрирующим такого рода влияние, являются изображения, приведённые на рис. 2. Из результатов такой обработки видно, что выравнивание пороговых значений в изображении при оценке мелких деталей при увеличении масштаба локализации функции $\Phi(\eta, x, y, \mu)$ за счёт уменьшения параметра μ приводит к трансформации (увеличению) размеров выделяемых деталей изображения (см. рис. 2б и в). При этом оценка параметров таких деталей становится более достоверной (рис. 2в). Это обуславливается ростом выборки помех, по которой определяются пороговые значения. Отметим, что описываемые выше процедуры имеют достаточно универсальный характер, а априорная информация, используемая при их реализации, относительно невелика.

Исследуем дополнительные детали работы КЗ-сети при обработке сигналов от отдельных сенсоров мультистатистической (распределённой) системы наблюдения [18, 19]. Такая предварительная обработка сигналов от отдельных сенсоров применяется к временным массивам измеряемых данных, при выравнивании уровней с сохранением контраста ожидаемых объектов наблюдения, а также оценке параметров полезных сигналов при наличии сильных нестационарных шумов. Обработка направлена прежде всего на ослабление шумов и помех, что позволяет существенно повысить эффективность операций сравнения. В общем случае такую обработку можно формально рассматривать как операцию в структуре решающей статистики.

Рассмотрим в качестве примера массив данных, соответствующий сигналу в виде импульса при наличии сильных шумов и помех. На рис. 3 показаны результаты предварительной обработки таких сигналов. Один из вариантов настройки КЗ-сети (2) аналогичен операциям преобразования контраста, которые обсуждались выше на примере обработки сигналов от совокупности сенсоров в составе мультистатистической сети в неоднородных нестационарных средах. При выполнении указанной операции отклик сети (см. рис. 3) характеризуется относительно низким уровнем шумов и помех, что позволяет существенно снизить пороговые значения при выполнении операций сравнения. Однако важно отметить, что положение сигнального импульса тем не менее определяется с большой точностью: этого было бы невозможно достичь при использовании традиционных линейных методов фильтрации. Как показывают численные эксперименты, на основе априорных данных о характере сигналов и помех можно подобрать параметры функций F_0 и Φ в уравнении (2) для выполнения, например, операции детектирования экстремальных значений сигнала, а также выделения участков сигнала с особыми амплитудно-частотными характеристиками, в частности, участков, где амплитуда сигнала спадает.

Нейроноподобные КЗ-системы, описываемые уравнениями типа (2), имеют широкие перспективы для решения задач адаптивного принятия решений при наблюдении, поскольку параметры таких систем, подстраиваясь под входные сигналы, обеспечивают эффективность и в случае существенных изменений условий наблюдения. Характер адаптации зависит от структуры нейроноподобной КЗ-системы, в частности, определяемой функциями Φ и F_0 , и, в рамках принятых в




Рис. 2. Влияние размеров области функции связи на преобразование контраста двумерного изображения из $2,0 \cdot 10^2 \times 2,5 \cdot 10^2$ значений величин $U(\delta t = 0,1)$ с помощью КЗ-сети (3): исходное изображение (а), преобразованное изображение при $\mu = 10^{-2}$ (б) и преобразованное изображение при $\mu = 0,5 \cdot 10^{-2}$ (в)

работе моделей, вектором значений их параметров $\{\delta, \Delta t, k, \mu\}$. Синтез сети, т. е. оптимальный выбор её структуры, должен основываться на априорном знании о характере решаемой задачи и условиях наблюдения. При адаптивном наблюдении априорная информация может формироваться как на основе предыдущих наблюдений, так и на построении эмпирических моделей поведения среды, объектов и помех.

В частном случае предварительной обработки изображений с помощью нейроноподобной КЗ-сети (рис. 1–3), в качестве такой априорной информации выступает размер мелких деталей, которые необходимо с высокой достоверностью обнаружить в пределах поля зрения с неоднородной освещённостью, а также величина и скорость вариаций освещённости. Динамика нейроноподобной КЗ-сети во времени зависит от структуры сети (функций Φ и F_0), а также от параметра δ , характеризующего временную память системы. Как уже отмечалось, при различных формах функций Φ и F_0 система может характеризоваться пространственно-временными структурами




Рис. 3. Результаты выделения импульса при наличии интенсивных шумов. Кривая 1 соответствует входному сигналу, кривая 2 — сигналу отклика сети

со сложным, в том числе автоколебательным поведением, что представляет интерес при использовании таких структур для динамического хранения информации в виде пространственно-временных образов. С этой точки зрения, важным является метод запоминания и распознавания, т. е. взаимодействие с такой памятью.

В подобной постановке формулируются задачи и при создании систем автоматического наблюдения в геофизических природных средах, которые относятся к классу обратных задач. Их решение сводится к выполнению процедур сравнения знакопеременных данных с выхода сенсоров с гипотезами о структуре наблюдаемых сигналов [18–23]. В природных условиях, когда среда и помехи являются неоднородными и нестационарными, необходимо использовать согласованные со средой адаптивное излучение и приём зондирующих сигналов (например, оптических или акустических). При этом пороги и решающие правила будут разными для различных интервалов оцениваемых параметров. Особенно остро указанная проблема стоит при создании систем мониторинга природных сред системой распределённых сенсоров, когда для решения задачи используется нейроноподобная среда, работа которой должна организовываться в автоматическом адаптивном режиме с использованием в том числе и когнитивных методов [18–20, 22]. Основной функцией такой нейроноподобной среды является сравнение поступающих от сенсоров данных с гипотезами, выполняемое в условиях сильных нестационарных помех и шумов. Как показывают исследования, перспективным методом решения задачи сравнения является использование нейроноподобных сред со свободной динамикой и контекстно-зависимыми параметрами [10, 21, 22].

Эффективным подходом адаптивного распознавания неоднородных и нестационарных объектов или образов является использование априорной информации в виде предположения, что наблюдаемый совокупностью сенсоров сигнал является суммой детерминированного тренда и случайной компоненты [24, 31, 32]. Для повышения устойчивости оценок параметров наблюдаемых неоднородных объектов необходимо ослабить влияние тренда, в частности, вариаций среднего уровня сигналов, возникающих из-за неоднородностей освещения и среды. Этого можно достигнуть, например, вычитанием модельных значений тренда из наблюдаемого неоднородного распределения. Статистическая структура получившегося остатка (невязки) формируется как совокупностью неконтролируемых случайных факторов, так и неадекватностью модели тренда. Ошибка модели тренда может иметь статистическое распределение с «тяжёлыми хвостами» из-за наличия выбросов. Последующая процедура оценки параметров чувствительна к наличию

выбросов. Статистики данных и процедуры их сглаживания будут соответствовать друг другу, если использовать нелинейные L_p -метрики [24, 31–33]. Как показано в [32], для различных статистических распределений невязок можно подобрать показатель степени p , обеспечивающий оптимальное сглаживание данных. При этом эффект воздействия на оценку «очень сильных» отклонений будет малым.

Использование описанной выше нелинейной процедуры сглаживания позволяет реализовать эффективный алгоритм адаптивного наблюдения в неоднородных нестационарных средах в виде статистической проверки гипотез. Такие гипотезы формируются на основе априорной информации об объектах наблюдения и помехах в виде моделей, описываемых вектором параметров $\mathbf{q}$. В качестве решения задачи наблюдения принимаются значения параметров модели $\mathbf{q} = \mathbf{q}_0$, при которых невязка максимально приближается к нормальному распределению, а её дисперсия принимает минимальное значение. При задании статистического критерия задача считается решённой при достижении требуемой достоверности. Как уже отмечалось, для успешной реализации указанного выше алгоритма необходимо использование достаточно большого объёма априорной информации о наблюдаемых объектах, шумах и помехах, получение которой может быть достаточно проблематично, особенно для наблюдения в неоднородных нестационарных средах. В этих условиях хорошие результаты могут быть достигнуты при использовании нейроподобных КЗ-сетей, которые, как показано выше, с помощью использования характеристик входных сигналов эффективно выполняют нелинейное выравнивание среднего уровня при сохранении информации о наблюдаемых деталях.

Рассмотрим возможности применения нейроподобной КЗ-сети при решении задачи статистической проверки гипотез о наличии объектов в наблюдаемых образах. Такая задача сводится к оценке значений параметров $\mathbf{q}$ модели $R(\mathbf{r}, t, \mathbf{q})$, которая формируется на основе априорной информации о наблюдаемом объекте. В качестве решения принимается значение $\mathbf{q} = \mathbf{q}_0$, при котором решающая статистика удовлетворяет принятому статистическому критерию. В качестве конкретной задачи рассмотрим случай, когда статистика сигналов и помех описывается нормальным распределением. Наблюдаемый сигнал от объекта наблюдения представляется в виде $U(\mathbf{r}, t, \mathbf{q}_0) = S(\mathbf{r}, t, \mathbf{q}_0) + n(\mathbf{r}, t)$, где $S(\mathbf{r}, t, \mathbf{q}_0)$ — формируемое объектом неоднородное распределение, а $n(\mathbf{r}, t)$ — стационарная помеха. В этом случае оптимальной решающей статистикой является L_2 -норма [32, 34], которую после соответствующей нормировки можно свести к свёртке измеряемого сигнала $U(\mathbf{r}, t, \mathbf{q}_0)$ с гипотезой (репликой) $R(\mathbf{r}, t, \mathbf{q})$. Полученная при использовании статистического критерия оценка $\hat{\mathbf{q}}$ будет удовлетворять заранее заданной достоверности. Решающая статистика $\Delta(\mathbf{r}, t, \mathbf{q})$ в этом случае зависит от вектора параметров гипотезы и будет иметь экстремальное значение лишь, когда $\mathbf{q} \rightarrow \mathbf{q}_0$.

Поскольку истинное решение заранее неизвестно, то для его поиска выполняется перебор гипотез в области, положение которой также определяется из априорной информации. При этом возникают трудности, связанные с изменениями статистического распределения значений $\Delta(\mathbf{r}, t, \mathbf{q})$, при большом отличии гипотез и наблюдаемых сигналов. В этих случаях при поиске решений необходимо оптимально подбирать структуру решающих статистик, в частности, при использовании L_p -норм правильно выбрать параметр p . Ещё большей трудностью использования обсуждаемого метода наблюдения является правильный выбор нормировки. Перечисленные особенности наблюдения показывают: для нестационарных и неоднородных сигналов и шумов, что имеет место в неоднородных нестационарных (природных) средах, построить устойчивые алгоритмы наблюдения с заранее заданными параметрами не представляется возможным. Единственным решением является адаптация алгоритмов к изменяющимся сигналам и помехам.

Если сигналы и помехи предполагаются неоднородными и нестационарными, то для устойчивости процедуры оценку можно выполнять с помощью нейроподобной КЗ-сети, которая поз-

воляет сравнить измеренные данные и тестовые (модельные) функции адаптивно к контексту. Рассмотрим подробнее структуру нейроноподобной КЗ-сети, выполняющей сравнение. При осуществлении такой операции каждый элемент сети (нейрон) активируется как измеряемыми данными $U(\mathbf{r}, t, \mathbf{q}_0)$, так и тестовыми функциями (гипотезами) $R(\mathbf{r}, t, \mathbf{q})$, моделируемыми на основе априорной информации. Отклик нейроноподобной КЗ-сети $\Delta(\mathbf{r}, t, \mathbf{q})$ при такой активации с учётом (2) при условии полного отсутствия какой-либо активации в начальный момент времени будет определяться следующим образом:

$$\Delta(\mathbf{r}, t, \mathbf{q}) = \int_0^{t+\infty} \int_{-\infty}^{\infty} F_0\{\Phi[\mathbf{r}, \mathbf{r}', \mathbf{r}'', U(\mathbf{r}, \mathbf{r}', t', \mathbf{q}_0), R(\mathbf{r}', \mathbf{r}'', t', \mathbf{q})], T[U(\mathbf{r}, \mathbf{r}', t', \mathbf{q}_0), R(\mathbf{r}', \mathbf{r}'', t', \mathbf{q})]\} \times \\ \times \varphi(t, t') d\mathbf{r}' d\mathbf{r}'' dt'. \quad (4)$$

Из (4) следует, что отклик сети $\Delta(\mathbf{r}, t, \mathbf{q})$ определён совокупностью активированных с некоторыми весами элементов в областях, зависящих как от измеряемой функции U , так и от тестовой функции R (реплики). Фактически интегрирование в (4) ограничено масштабом локализации функции связи, которые определены контекстом и априорной информацией. Таким образом, они могут меняться не только в зависимости от измеряемых сигналов и априорной информации в виде тестовых функций, но и в зависимости от своих предыдущих значений, что определяется функцией динамической памяти $\varphi(t, t')$. Такие сети могут иметь сложную динамику.

Задача синтеза оптимальных структур подобных сетей заключается в правильном выборе вида пороговых функций F_0 и функций связи. Можно полагать, что, как и случае КЗ-сетей типа (1)–(3), при выполнении условий стационарной динамики [18, 19] сеть (4) может принимать динамические состояния в виде устойчивых состояний равновесия, периодических и сложных квазипериодических колебаний. Эти состояния могут быть стационарными при компенсации диссипации внешними источниками и сохранять информацию о характере активации в виде обобщённых динамических образов в пространстве $(\mathbf{r}, t, \mathbf{q})$. Для извлечения (вспоминания) исходных сигналов из обобщённых динамических образов следует параметризовать такие образы совокупностью характеристик настройки сети и соответствующих динамическим образам тестовых распределений.

При сравнении локальный отклик определяется областью, зависящей от функции связи и локальных параметров измеряемых сигналов в этой области, а также от гипотез, выдвигаемых на основе априорной информации. Отклик сети (4) на инициацию может иметь сложную пространственно-временную структуру, которая будет зависеть от параметров возбуждения сети $\mathbf{q}$ и характеризовать степень близости измеряемого сигнала и гипотезы. Поскольку локальные значения откликов могут иметь низкую достоверность, для эффективного и устойчивого сравнения можно использовать интегральный отклик сети:

$$\Delta_{\Sigma}^C(\mathbf{q}) = \int_{-\infty}^{+\infty} \int_0^t \Delta(\mathbf{r}, t, \mathbf{q}) G(\mathbf{r}, t) dt d\mathbf{r}. \quad (5)$$

Здесь $G(\mathbf{r}, t)$ — комплексный весовой множитель, определяемый пространственно-временной структурой отклика на сравниваемые сигналы, позволяет максимально эффективно накопить (проинтегрировать) отклик $\Delta(\mathbf{r}, t, \mathbf{q})$. При таком суммировании функция $G(\mathbf{r}, t)$ должна компенсировать фазовые характеристики отклика, а также выровнять амплитудные значения.

Смысл таких преобразований заключается в уменьшении влияния трендов, связанных с сигналом, что позволяет принимать более достоверные решения, поскольку статистические распределения интегрального отклика сети $\Delta_{\Sigma}^C(\mathbf{q})$ будут становиться нормальными [24, 32]. Выпол-

нение операции (5) предполагает использование априорной информации о структуре комплексной функции $\Delta(\mathbf{r}, t, \mathbf{q})$, которая определяется характеристиками наблюдаемого сигнала. При её наличии возможно наиболее эффективное когерентное накопление локальных откликов трансформирующей измеряемый сигнал КЗ-сети, что существенно повышает устойчивость и чувствительность выполняемой ею операции сравнения. Часто при решении практических задач объём априорной информации о структуре функции $\Delta(\mathbf{r}, t, \mathbf{q})$ бывает ограничен. Например, такая ситуация имеет место в мультистатистической системе наблюдения, когда связь между её элементами ограничена. В этом случае можно использовать некогерентное накопление:

$$\Delta_{\Sigma}^{\text{NC}}(\mathbf{q}) = \int_{-\infty}^{+\infty} \int_{-\infty}^t |\Delta(\mathbf{r}, t, \mathbf{q})| |G(\mathbf{r}, t)| dt d\mathbf{r}. \quad (6)$$

При более существенном недостатке априорной информации формирование интегральных оценок можно ограничить суммированием лишь парциальных (локальных) оценок, например, логическим накоплением вероятностей правильного решения [18–21].

Интегральные отклики КЗ-сети $\Delta_{\Sigma}(\mathbf{q})$ зависят от вектора параметров наблюдаемого объекта. Поскольку тестовые функции (гипотезы) $R(\mathbf{r}, t, \mathbf{q})$ формируются на основе априорной информации о наблюдаемом объекте, наблюдение (оценка значений параметров объектов) заключается в статистической проверке гипотез о значениях $\mathbf{q}$. Принятие решения при наблюдении объектов осуществляется при максимизации решающей статистики $\Delta_{\Sigma}(\mathbf{q})$ при $\mathbf{q} \rightarrow \mathbf{q}_0$, когда вектор параметров в процессе перебора совпадет с истинным значением. В этом случае оценка будет максимально устойчивой и правдоподобной.

Полномасштабное исследование рассматриваемых КЗ-сетей типа (4) необходимо осуществлять на основе использования методов нейродинамики. В данной работе мы ограничимся лишь анализом эффективности выполнения операции сравнения при мультистатистическом наблюдении в неоднородной нестационарной среде на основе численного моделирования. Этот анализ будем выполнять на примере базовой задачи, которая лежит в основе наблюдения с помощью зондирования сложно модулированными импульсами.

Задача заключается в оценке параметров импульсов, рассеянных объектом наблюдения. Для этого обычно используется метод проверки гипотез с помощью алгоритма сравнения. В качестве оцениваемых параметров чаще всего выступают задержка импульса τ и доплеровское смещение несущей частоты импульса Ω , т. е. $\mathbf{q} = \{\tau, \Omega\}$. При решении такой задачи измеряемый (входной) сигнал U является одномерным. Для упрощения анализа будем считать, что динамическая память у сети отсутствует. При численном моделировании будем полагать, что $U(t, \tau_0, \Omega_0) = S(t, \tau_0, \Omega_0) + n(t)$, где $S(t, \tau_0, \Omega_0) = A(t - \tau_0) \sin[(\omega - \Omega_0)(t - \tau_0) + \gamma(t - \tau_0)^2]$ — импульс с линейной частотной модуляцией (ЛЧМ) и огибающей

$$A(t - \tau_0) = \begin{cases} A_0, & |t - \tau_0| \leq \tilde{T}/2; \\ 0, & |t - \tau_0| > \tilde{T}/2, \end{cases}$$

$\tilde{T}$ — длина импульса, γ — коэффициент перестройки частоты, τ_0 и Ω_0 — истинные значения задержки и частотного смещения, $n(t)$ — шум с равномерным в интервале амплитуд $(-B, B)$ статистическим распределением.

В качестве гипотез будем использовать функции $R(\mathbf{r}, t, \mathbf{q}) \equiv S(t, 0, \tau, \Omega)$. С учётом особенностей рассматриваемой задачи, а также вида сравниваемых функций будем исследовать отклик $\Delta(t, \tau, \Omega)$ КЗ-сети, в которой функция связи Φ определяется гипотезой R в локальном интервале $[t - a, t + a]$. Будем также полагать, что функция T , определяющая уровни активации в связанных




Рис. 4. Формирование отклика (7) при неадаптивном (кривая 1) и адаптивном (кривая 2) сравнении. Кривая 3 соответствует эталонному сигналу, кривая 4 — зашумлённому сигналу

точках, зависит не только от значений R в локальном временном интервале $[t - a, t + a]$, но и от значений измеряемой функции S в локальном интервале $[t - b, t + b]$. Определим параметры a и b в интервалах функций S и R так, чтобы a и b были обратно пропорциональны амплитудам R и S , т. е. $a \approx \max[R(t)]/R(t)$ и $b \approx \max[S(t)]/S(t)$. С учётом указанных соображений, будем далее исследовать эффективность выполнения операции сравнения с помощью КЗ-сети, локальный отклик которой определяется следующим образом:

$$\Delta(t, \tau, \Omega) = R(t, \tau, \Omega) \times F \left[- \left| \int_{t-a}^{t+a} R(t', \tau, \Omega) dt' \right|, \left\{ \int_{t-b}^{t+b} S(t', \tau_0, \Omega_0) dt' - \int_{t-a}^{t+a} R(t', \tau, \Omega) dt' \right\} \text{sign}[R(t, \tau, \Omega)] \right], \quad (7)$$

где

$$F[\Phi(t), T(t)] = \begin{cases} 0, & \Phi(t) \leq T(t); \\ 1, & \Phi(t) > T(t). \end{cases}$$

Как видно из структуры (7), существенный вклад в отклик $\Delta(t, \tau, \Omega)$ сети формируется во временных интервалах, где разность фаз измеренного и тестового сигналов меняется несущественно (см. рис. 4). Из сравнения формирования адаптивного отклика (7) и обычно используемого неадаптивного алгоритма (см. рис. 4). Видно, что корреляция указанных функций при использовании алгоритма (7) существенно выше.

Возможности КЗ-сети (7) при сравнении сигналов сложной природы были проанализированы на основе численного моделирования. В частности, выполнялось сравнение устойчивости относительно уменьшения отношения сигнал/шум алгоритма (7) и процедур сравнения, выполняемых на основе ковариационной свёртки и вычисления L_2 -нормы. Как показали численные эксперименты (см. рис. 5), нейроноподобная структура (7) обеспечивала существенно большую устойчивость к шумам, в частности, по сравнению с часто используемым ковариационным методом сравнения. На рис. 5 показана зависимость интегрального отклика $\Delta_{\Sigma}^{\text{NC}}(\tau, \Omega)$ для различных уровней равномерного шума при использовании КЗ-сети (7) и алгоритма, основанного на вычислении ковариационной функции. Как видно из приведённых на рис. 5 и других вычислений,




Рис. 5. Зависимость интегрального отклика $\Delta_{\Sigma}^{NC}(\tau, \Omega)$ при использовании алгоритма, основанного на вычислении ковариационной функции (а, б), и КЗ-сети (7) (б, г) при различных отношениях уровня сигнала к уровню равномерного шума: -16 дБ (а, б) и -37 дБ (в, г)




Рис. 5 (продолжение)

КЗ-сеть позволяет существенно более эффективно осуществлять операцию наблюдения, которая в рассмотренном случае заключается в оценке параметров измеряемого сигнала $\tau = \tau_0$, $\Omega = \Omega_0$,

соответствующих положению глобального экстремума $\Delta_{\Sigma}^{NC}(\tau_0, \Omega_0)$.

Прежде всего, это проявляется в большем разрешении в пространстве параметров (τ, Ω) , которое достигается при использовании КЗ-сети. В рассматриваемом численном эксперименте при использовании одинаковых зондирующих ЛЧМ-импульсов пространственное разрешение более чем на порядок больше, чем при использовании корреляционной свёртки (рис. 5а, б). Кроме того, уровень корреляционного шума, связанного со скоростью уменьшения взаимной энергии по мере отстройки значений параметров гипотез от истинных значений, оказывается существенно меньше в случае выполнения операции свёртки с помощью КЗ-сети. Как видно из численных экспериментов, уровень корреляционных помех при использовании нейроноподобной свёртки на $10 \div 15$ дБ меньше.

Помехозащищённость алгоритма сравнения в обоих случаях уменьшается с ростом уровня шумовой помехи. Это проявляется в уменьшении амплитуды экстремума функции невязки по отношению к уровням решающей статистики, соответствующим большим значениям рассогласования, а также в появлении большого числа ложных локальных экстремумов, т. е. решение становится неоднозначным и недостоверным. Кроме того, оценка решения (положения глобального экстремума) становится смещённой. Однако необходимо отметить, что такая точность может быть достигнута лишь вблизи решения, т. е. при наличии априорной информации. При отсутствии априорной информации интервал поиска велик и нахождение решения будет затруднено наличием множества локальных экстремумов.

Эффективность использования L_2 -нормы [16, 27] в качестве решающей статистики при выполнении операций сравнения существенно зависит от правильности выбора нормировки. Для определения корректной нормировки требуется знание статистического распределения шумов [10, 19, 21, 22]. Сопоставление нейросетевой процедуры с другими методами показывает, что её важным достоинством является автоматическое нормирование функции невязки. Кроме того, такая процедура даёт возможность организации параллельных вычислений. При этом эффективность нейросетевой свёртки относительно слабо зависит от статистического распределения шумов. Если в качестве решающей статистики используются L_p -нормы, то необходим подбор параметра p , что возможно при наличии априорной информации о статистическом распределении шумов [24, 31–33].

3. ОПЕРАЦИИ НАД СЛОЖНЫМИ СИГНАЛАМИ С ПОМОЩЬЮ НЕЙРОНОПОДОБНЫХ КЗ-СЕТЕЙ

Нейроноподобная КЗ-сеть (7), осуществляющая процедуру сравнения, позволяет также осуществлять и операции над сложными сигналами. При подаче на два входа сигналов $S = S_1$ и $S = S_2$ сеть (7) формирует на выходе результирующий сигнал по следующим правилам. На участках совпадения характеристик сигналов значения выходного сигнала совпадают со значениями эталонного сигнала. В противном случае значения выходного сигнала либо равны нулю, либо совпадают со значениями на сигнальном входе. В первом случае таким методом можно реализовать конъюнктивную операцию (в дальнейшем будем обозначать её символом « $\otimes$ »), во втором случае — дизъюнктивную операцию (в дальнейшем будем обозначать её символом « $\oplus$ »). Указанные процедуры иллюстрируются на рис. 6, где показаны сигналы S_1 и S_2 и результаты выполнения операций над ними.

Анализируя характеристики выходных сигналов, мы можем выделить основные законы «нейроопераций» над сигналами и, в частности, закон некоммутативности: $S_1 \otimes S_2 \neq S_2 \otimes S_1$, $S_1 \oplus S_2 \neq S_2 \oplus S_1$. Важно то, что последовательность формирования результирующего «обобщённого» сигнала влияет на его вид и структуру. Приведённые выше способы формирования «обобщённо-




Рис. 6. Результаты выполнения различных операций над сигналами S_1 и S_2 : $S_1 \otimes S_2$ (а), $S_2 \otimes S_1$ (б), $S_1 \oplus S_2$ (в), $S_2 \oplus S_1$ (г). Сигналам соответствуют пунктирные линии, результатам выполнения операций — сплошные линии

го» сигнала демонстрируют принципиальные возможности осуществления таких процедур. Они используют принцип модификации амплитудно-частотных характеристик сигналов. Известно, что более продуктивным с точки зрения шумовой устойчивости является манипулирование фазой. Поэтому более эффективным может быть синтез нейросетевых процедур, где формирование «обобщённого» сигнала осуществляется на основе модификации фазовых характеристик.

4. ЗАКЛЮЧЕНИЕ

Как показывают представленные выше результаты, нейроноподобные структуры свободной динамики с контекстно-зависимыми параметрами характеризуются высокой эффективностью при выполнении процедур предварительной обработки и классификации реальных сложных сигналов, регистрируемых сенсорными системами при наличии сильных шумов. Это открывает широкие возможности их использования при создании систем наблюдения в природных пространственно-неоднородных нестационарных волноводах, где необходимо использование адаптивных контекстно-зависимых решающих правил [18–21].

Практический интерес представляют приведённые в работе соображения по классификации нейронных сетей по их динамике, что может вызвать особый интерес при разработке когнитивных моделей сознания живых систем [7–13]. Можно предположить, что такие структуры лучше описывают свойства естественных биологических систем. Рассмотренные в работе сети свободной динамики могут также быть полезны при анализе механизмов формирования памяти.

СПИСОК ЛИТЕРАТУРЫ

1. Carpenter G., Grossberg S. A. // Computer Vision, Graphics, and Image Understanding. 1987. V. 37. P. 54.
2. Fukushima K. // NHK Technical Monograph. 1981. No. 30. P. 34.
3. Fukushima K., Miyake S. // Pattern Recognition. 1982. V. 15. P. 455.

4. Широков Ф. В. Итоги науки и техники. Физические и математические модели нейронных сетей. Т. 1. Часть 1. Спиновые стёкла и нейронные сети. М.: ВИНТИ, 1990. С. 229.
5. Haykin S. Neural networks: a comprehensive foundation. Ontario: McMaster University Hat Shop, 1982. 346 p.
6. Мастеров А. В., Рабинович М. И., Толков В. Н. и др. // Коллективная динамика возбуждений и структурообразование в биологических тканях. Горький: ИПФ АН СССР, 1988. С. 89.
7. Мастеров А. В., Яхно В. Г. // Коллективная динамика возбуждений и структурообразование в биологических тканях. Горький: ИПФ АН СССР, 1988. С. 89.
8. Беллюстин Н. С. О динамике структур в искусственных нейронных сетях с латеральной конкуренцией элементов: Препринт № 234 НИРФИ. Нижний Новгород, 1993. 25 с.
9. Belliustin N. S., Kuznetsov S. O., Nuideil I. V., et al. // Neurocomputing. 1991. No. 3. P. 231.
10. Khobotov A., Khilko A., Yakhno V. // Opt. Memory and Neural Networks (Information Optics). 2008. V. 17, No. 4. P. 299.
11. Доценко В. С., Иоффе Л. Б., Фейгельман М. В., Цодыкс М. В. Итоги науки и техники. Физические и математические модели нейронных сетей. Т. 1. Часть 1. Спиновые стёкла и нейронные сети. М.: ВИНТИ, 1990. С. 124.
12. Nicolis J. S. Dynamics of hierarchical systems: an evolutionary approach. Berlin: Springer-Verlag, 1986. 235 p.
13. Kryzhanovsky B. V., Kryzhanovsky M. V., Fonarev A. // Opt. Memory and Neural Network. 2001. V. 10, No. 2. P. 91.
14. Абарбанель Г. Д. И., Рабинович М. И., Селверстон А. И. др. // УФН. 1996. Т. 166, № 4. С. 363.
15. Некоркин В. И. // УФН. 2008. Т. 178, № 3. С. 314.
16. Осовец С. М., Гинзбург Д. А., Гурфинкель В. С. // УФН. 1983. Т. 141, № 1. С. 103.
17. Хакен Г., Хакен-Крелль М. Тайны восприятия. М.: Институт компьютерных исследований, 2002. 272 с.
18. Лучинин А. Г., Хилько А. И. // УФН. 2011. Т. 181, № 11. С. 22.
19. Хилько А. И., Яхно В. Г., Хоботов А. Г. и др. // Тр. XXII Сессии Российского акустического общества и сессии Научного совета по акустике РАН. М.: ГЕОС, 2010. С. 244.
20. Пат. № 207130876 РФ. Способ адаптивного распознавания объектов / В. А. Сборщиков, В. В. Воскресенский, А. И. Хилько и др.; Зарегистрирован 10.03.2008.
21. Хоботов А. Г., Хилько А. И., Яхно В. Г. и др. // Тр. Всерос. конф. «Нелинейная динамика в когнитивных системах». Нижний Новгород: ИПФ РАН, 2011. С. 214.
22. Хилько А. И., Яхно В. Г., Хоботов А. Г. и др. // Тр. Всерос. конф. «Нелинейная динамика в когнитивных системах». Нижний Новгород: ИПФ РАН, 2011. С. 210.
23. Лазарев В. А., Малеханов А. И., Мерклин Л. Р. и др. // Акуст. журн. 2012. Т. 58, № 2. С. 227.
24. Коваленко В. В., Хилько А. И., Романова В. И. // Тр. XIII Школы-семинара им. акад. Л. М. Бреховских «Акустика океана», совмещенной с XXIII Сессией Российского акустического общества. М.: ГЕОС, 2011. С. 346.
25. Aihara K. // Studies in Computational Intelligence. Berlin: Springer, 2009. V. 184. P. 231.
26. Синай Я. Г. Теория фазовых переходов: строгие результаты. М.: Наука, 1980. 287 с.
27. Колмогоров А. Н. // Докл. АН СССР. 1958. Т. 119. С. 861.
28. Синай Я. Г. // Докл. АН СССР. 1959. Т. 124. С. 768.
29. Заславский Г. М., Сагдеев Р. З. Введение в нелинейную физику: от маятника до турбулентности и хаоса. М.: Наука, 1988. 368 с.
30. Соколова Л. С., Маминская Р. И. // Физиология человека. 2006. Т. 32, № 5. С. 5.
31. Хоботов А. Г., Романова В. И., Хилько А. И. // Тр. Нижегородской акустической научной сессии 13–14 мая 2008 года. Нижний Новгород: ТАЛАМ, 2008. С. 128.

32. Романова В. И., Лазарев В. А., Хилько А. И. // Тр. XI Научной конф. по радиофизике, посвященной 105-летию со дня рождения М. Т. Греховой, 7 мая 2007 года. Нижний Новгород: ТАЛАН, 2007. С. 195.
33. Романова В. И., Лазарев В. А., Хилько А. И. // Тр. XII Научной конф. по радиофизике, посвященной 90-летию со дня рождения М. М. Кобрин, 7 мая, 2008 года. Н. Новгород: ТАЛАН, 2008. С. 208.
34. Ярославский Л. П. Введение в цифровую обработку изображений. М.: Сов. радио, 1979. 345 с.

Поступила в редакцию 22 февраля 2013 г.; принята в печать 15 марта 2013 г.

**USING FREE-DYNAMICS NEURAL-NETWORK STRUCTURES
WITH CONTEXT-DEPENDENT PARAMETERS FOR OBSERVATION
IN INHOMOGENEOUS NONSTATIONARY MEDIA**

A. G. Khbotov, A. I. Khil'ko, and V. I. Romanova

We discuss a classification of neural networks by their dynamics. The results of numerical analysis of the possibilities of using free-dynamics neuron-like structures with context-dependent parameters for adaptive observation in complex nonstationary media are presented. The efficiency of solution of such problems by using neuron-like structures compared with other conventional methods is analyzed.