

УДК 004.93

С. А. Субботин

Запорожский национальный технический университет
ул. Жуковского, 64, 69063 Запорожье, Украина

Анализ свойств и критерии сравнения нейросетевых моделей для решения задач диагностики и распознавания образов

Предложен комплекс критериев, позволяющих численно оценивать свойства нейронных и нейро-нечетких сетей: пластичность, однородность, параллелизм вычислений, иерархичность, предорганизацию в обучении, функциональную блочность, обобщение, обучаемость, интерпретабельность, надежность, распределенность памяти, вариативность моделей, эффективность. Применение предложенных критериев на практике позволяет автоматизировать процесс построения нейросетевых моделей для решения задач диагностики и распознавания образов.

Ключевые слова: *нейронная сеть, нейро-нечеткая сеть, критерий сравнения, распознавание образов.*

Введение

При решении задач автоматизации процедур технической диагностики и неразрушающего контроля качества, а также распознавания образов по признакам широкое распространение получили однородные сетевые вычислительные структуры, представляющие собой массивованно-параллельные соединения простых, обычно адаптивных элементов (нейронов), имеющих непустое множество входов, вместе с их иерархической организацией, обладающее свойствами нелинейности (целое суммы частей), нелокальности (дальнодействия), нестационарности (обучаемости) и обратной связи (исключение бесконечного регресса) [1].

Наиболее значимыми классами сетевых вычислительных структур являются искусственные нейронные [1, 2] и нейро-нечеткие сети [3]. В настоящее время разработан широкий спектр моделей и методов построения нейронных и нейро-нечетких сетей [1–3]. Такое разнообразие существующих моделей приводит к необходимости решения задачи автоматизации анализа свойств и сравнения сетевых вычислительных моделей.

Целью данной работы являлось создание математического обеспечения для автоматизации анализа свойств и сравнения сетевых вычислительных моделей.

© С. А. Субботин

Постановка задачи

Пусть задана обучающая выборка $\langle x, y \rangle$, где $x = \{x^s\}$; $x^s = \{x_j^s\}$; $y = \{y^s\}$; $s = 1, 2, \dots, S$; $j = 1, 2, \dots, N$; x^s — s -й экземпляр выборки; x_j^s — значение j -го признака s -го экземпляра; S — число экземпляров выборки; N — число признаков; y^s — значение выходного признака, сопоставленное s -му экземпляру выборки, на основе которой синтезирована нейронная или нейро-нечеткая сеть. Поскольку наиболее широко используемым типом сетей являются слоистые сети прямого распространения, будем характеризовать сети кортежем $\langle M, \{N_\eta\}, \{\langle \{w_j^{(\eta,i)}\}, \varphi^{(\eta,i)}, \psi^{(\eta,i)} \rangle\} \rangle$, где M — число слоев сети; N_η — количество нейронов в η -м слое сети; $w_j^{(\eta,i)}$ — весовой коэффициент j -го входа i -го нейрона η -го слоя; $\varphi^{(\eta,i)}$ — дискриминантная функция i -го нейрона η -го слоя; $\psi^{(\eta,i)}$ — функция активации i -го нейрона η -го слоя. Также обозначим: N_n — число нейронов в сети; N_w — количество настраиваемых параметров (весов) сети; $\varphi(i)$, $\psi(i)$ — соответственно дискриминантная и активационная функции i -го нейрона (при сплошной нумерации нейронов сети); w_{ij} — вес связи между i -м и j -м нейронами сети (если связь отсутствует, примем $w_{ij} = 0$), где $i, j = 1, 2, \dots, N_n$.

Для автоматизации сравнительного анализа нейромоделей необходимо разработать набор показателей, а также методы их расчета, отражающие важнейшие свойства нейромоделей. Целесообразно при этом обеспечить такой масштаб шкалы критериев, при котором они будут легко объединяться друг с другом.

Анализ литературы

Наиболее широко используемыми критериями сравнения нейросетевых моделей являются точность, характеризующая ошибкой обучения и ошибкой распознавания тестовых данных, время и количество итераций, затраченных на процесс обучения, время распознавания тестовых данных, число слоев и нейронов сети [1, 2]. В [2] предложен ряд способов для оценки сложности нейросетей (НС). Однако такой набор показателей отражает лишь небольшую часть свойств нейромоделей. Поэтому автором в [4, 5] ранее был предложен комплекс критериев, характеризовавших сложность, избыточность памяти, логическую прозрачность и качество аппроксимации нейросетевых моделей.

Однако такие важные свойства НС как пластичность, однородность, параллелизм вычислений, иерархичность, предорганизация в обучении, функциональная блочность, обобщение, обучаемость, интерпретируемость, надежность, распределенность памяти, вариативность моделей, эффективность до настоящего момента времени либо не имели аналитических формул для количественного выражения, либо оценивались показателями с различными диапазонами значений. Поэтому в настоящей работе именно данные свойства выбраны для анализа.

Свойства структуры нейромодели

К свойствам архитектуры нейромодели следует отнести пластичность, однородность, параллелизм, иерархичность, предорганизацию в обучении и функцио-

нальную блочность.

Пластичность — обуславливает сложность поведения НС, которое рассматривается как результат взаимодействия многих элементов, каждый из которых ограничивает действие других и сам ограничивается другими на пути к формированию глобального наблюдаемого поведения. Различают нейронную пластичность (в качестве пластических элементов рассматриваются нейроны), а также синаптическую пластичность (модификация силы синаптической связи между нейронами) [7].

Относительный коэффициент нейронной пластичности зададим как:

$$I_{np} = \frac{\sum_{i=1}^{N_n} \mathcal{G}_{np}(\varphi(i)) \mathcal{G}_{np}(\psi(i))}{N_n^{\max} \mathcal{G}_{np}^{\max}(\varphi) \mathcal{G}_{np}^{\max}(\psi)},$$

где N_n^{\max} — максимально возможное количество нейронов; $\mathcal{G}_{np}(element)$ — характеристика пластичности функционального элемента $element$ нейрона (будем полагать $\mathcal{G}_{np}(element)$ равным числу возможных состояний элемента $element$: для дискриминантной функции i -го нейрона $\mathcal{G}_{np}(\varphi(i))$ будет равняться числу возможных видов дискриминантных функций, которые могут быть заданы для данного нейрона; для функции активации i -го нейрона $\mathcal{G}_{np}(\psi(i))$ будет равняться числу возможных видов функций активации, которые могут быть заданы для данного нейрона); $\mathcal{G}_{np}^{\max}(\varphi), \mathcal{G}_{np}^{\max}(\psi)$ — соответственно максимальные характеристики пластичности дискриминантных и активационных функций среди всех нейронов сети.

Относительный коэффициент нейронной пластичности сети будет принимать значения в диапазоне от 0 до 1: чем больше будет его значение, тем выше уровень нейронной пластичности сети.

Относительный коэффициент синаптической пластичности сети определим как:

$$I_{sp} = \frac{\sum_{i=1}^{N_n} \sum_{j=1}^{N_n} \mathcal{G}_{sp}(i, j)}{N_n^2 \text{round}\left(\frac{w^{\max} - w^{\min}}{\Delta w}\right)},$$

где w^{\max}, w^{\min} — соответственно максимальное и минимальное возможные значения весов сети; Δw — минимально возможное изменение веса с учетом разрядности вычислительной сетки ЭВМ; round — функция округления к ближайшему целому числу; $\mathcal{G}_{sp}(i, j)$ — характеристика пластичности связи от i -го нейрона к j -му ($\mathcal{G}_{sp}(i, j) = 0$, если связь не может существовать, либо связь жестко задана, и ее вес не может изменяться; в остальных случаях:

$$g_{sp}(i, j) = \text{round} \left(\frac{w_{i,j}^{\max} - w_{i,j}^{\min}}{\Delta w_{i,j}} \right),$$

где $w_{i,j}^{\max}, w_{i,j}^{\min}$ — соответственно максимальное и минимальное возможные значения веса связи от i -го нейрона к j -му; $\Delta w_{i,j}$ — минимально возможное изменение веса с учетом размера разрядной сетки ЭВМ.

Относительный коэффициент синаптической пластичности сети будет принимать значения в диапазоне от 0 до 1: чем больше будет его значение, тем выше уровень синаптической пластичности сети при фиксированном количестве нейронов.

Относительный коэффициент пластичности сети определим на основе введенных относительных коэффициентов нейронной и синаптической пластичностей: $I_{pl} = I_{np} I_{sp}$.

Относительный коэффициент пластичности сети будет принимать значения в диапазоне от 0 до 1: чем больше будет его значение, тем выше уровень пластичности сети и, следовательно, сеть обладает большими адаптационными способностями.

Однородность нейроэлементов сети заключается в том, что нейросети строятся из множества простых унифицированных типовых элементов (нейронов), выполняющих элементарные действия (умножение, сложение, вычисление простейшей нелинейной функции) и соединенных между собой различными связями [2].

Однородность дискриминантных функций будем оценивать как:

$$I_{hd} = \frac{2 \sum_{i=1}^{N_H} \sum_{j=i}^{N_H} \{1 | \varphi(i) \equiv \varphi(j)\}}{N_H (N_H - 1)}.$$

Однородность функций активации предлагается определять по формуле:

$$I_{ha} = \frac{2 \sum_{i=1}^{N_H} \sum_{j=i}^{N_H} \{1 | \psi(i) \equiv \psi(j)\}}{N_H (N_H - 1)}.$$

Однородность нейронов сети определим как:

$$I_h = \frac{2 \sum_{i=1}^{N_H} \sum_{j=i}^{N_H} \{1 | (\psi(i) \equiv \psi(j)) \wedge (\varphi(i) \equiv \varphi(j))\}}{N_H (N_H - 1)}.$$

Показатели однородности будут изменяться от 0 до 1: чем больше будут их значения, тем более однородны соответствующие элементы сети.

Параллельная архитектура и распределенность вычислений — обработка информации в НС выполняется несколькими процессорными элементами, в то время как в обычных компьютерах, имеющих только один центральный процессор, информация обрабатывается последовательно, по шагам [1, 2].

Параллелизм вычислений сети прямого распространения без латеральных связей будем характеризовать с помощью критерия:

$$I_{par} = \frac{\sum_{\eta=1}^M \frac{1}{\eta} \sum_{i=1}^{N_{\eta}} (N_{\eta-1} + 3)}{N_w + 2N_n}.$$

Иерархическая организация структуры, целостность и дробимость элементов НС: использование иерархических структур — позволяет строить модели сложных объектов из более простых; работа иерархической структуры требует, чтобы информационный элемент в каждом иерархическом уровне вел себя как единое целое, но при переходе с уровня на уровень допускал дробление, причем при переходе с верхнего иерархического уровня на нижний это дробление соответствует выделению составляющих его элементов, а при переходе с нижнего уровня на верхний оно соответствует включению определенной части этого элемента в более сложный объект [6].

Определим иерархичность сети как:

$$I_h = \frac{\sum_{\eta=1}^M \eta N_{\eta}}{MN_n}.$$

Предорганизация в обучении — свойство сети, отражающее ее пригодность для решения задачи в начале процесса структурно-параметрической идентификации [6]. Данное свойство будем характеризовать набором следующих показателей.

Относительный показатель предорганизации в обучении определим как:

$$I_{po} = \frac{1}{2N_w} \sum_{\eta=1}^M \sum_{i=1}^{N_{\eta}} \sum_{j=1}^{N_{\eta-1}} \mathcal{G}_{po}(w_j^{(\eta,i)}) + \frac{1}{4N_n} \sum_{\eta=1}^M \sum_{i=1}^{N_{\eta}} \mathcal{G}_{po}(\varphi^{(\eta,i)}) + \frac{1}{4N_n} \sum_{\eta=1}^M \sum_{i=1}^{N_{\eta}} \mathcal{G}_{po}(\psi^{(\eta,i)}),$$

где M — количество слоев в сети; N_n — количество нейронов в сети; \mathcal{G}_{po} — эвристическая функция, показывающая степень неслучайности задания значения параметра сети в предорганизации ее обучения:

$$\mathcal{G}_{po}(element) = \begin{cases} 0, & element = rand, \\ 1, & element \neq rand, \end{cases}$$

либо

$$\mathcal{G}_{po}(element) = 1 - \frac{\max(rand) - \min(rand)}{\max(element) - \min(element)},$$

где $element$ — условное обозначение параметра функции; $rand$ — случайная компонента элемента.

Относительный показатель автоматизации предорганизации в обучении зададим как:

$$I_{apo} = \frac{\mathcal{G}_L + \mathcal{G}_H}{4} + \frac{1}{4N_w} \sum_{\eta=1}^M \sum_{i=1}^{N_\eta} \sum_{j=1}^{N_{\eta-1}} (\mathcal{G}_a(w_j^{(\eta,i)}) \mathcal{G}_{po}(w_j^{(\eta,i)})) + \\ + \frac{1}{8N_H} \sum_{\eta=1}^M \sum_{i=1}^{N_\eta} (\mathcal{G}_a(w_j^{(\eta,i)}) \mathcal{G}_{po}(\varphi^{(\eta,i)})) + \frac{1}{8N_H} \sum_{\eta=1}^M \sum_{i=1}^{N_\eta} (\mathcal{G}_a(w_j^{(\eta,i)}) \mathcal{G}_{po}(\psi^{(\eta,i)})),$$

где \mathcal{G}_L — эвристическая мера, показывающая степень автоматизации задания числа слоев в предорганизации обучения сети ($\mathcal{G}_L = 1$, если число слоев определяется автоматически; в противном случае — принимают $\mathcal{G}_L = 0$); \mathcal{G}_H — эвристическая мера, показывающая степень автоматизации задания числа нейронов в предорганизации обучения сети ($\mathcal{G}_H = 1$, если число нейронов определяется автоматически; в противном случае — принимают $\mathcal{G}_H = 0$); $\mathcal{G}_a(element)$ — эвристическая функция, показывающая степень автоматизации задания значения параметра $element$ сети в предорганизации ее обучения ($\mathcal{G}_a(element) = 0$, если значение параметра $element$ задает пользователь, в противном случае — $\mathcal{G}_a(element) = 1$).

Функциональная блочность — свойство построения архитектуры сети из стандартизированных функциональных блоков, внутренняя организация и свойства которых определены заранее и известны разработчику [6].

Поскольку все нейронные и нейро-нечеткие сети по своей природе состоят из нейронов, обладающих однотипностью выполняемых операций, относительную функциональную блочность будем рассматривать на внешнем уровне по отношению к уровню нейронов:

$$I_{fb} = 1 - \frac{2 \sum_{i=1}^{N_H} \sum_{j=i+1}^{N_H} \mathcal{G}_{fb}(i, j)}{N_H(N_H - 1)},$$

где $\mathcal{G}_{fb}(i, j)$ — показатель принадлежности i -го и j -го нейронов сети к одному и тому же функциональному блоку ($\mathcal{G}_{fb}(i, j) = 1$, если нейроны принадлежат к одному и тому же блоку, $\mathcal{G}_{fb}(i, j) = 0$ — в противном случае).

Если уровень функциональной блочности равен нулю, это означает, что разработчику сети понятны только преобразования на уровне конкретных нейронов, однако нет таких групп нейронов, функции которых были бы понятны. Если же

уровень функциональной блочности равен единице, то все нейроны сети объединены в систему блоков, функционирование которых понятно на более высоком уровне, чем уровень конкретного нейрона.

Свойства параметров нейромодели

К свойствам настраиваемых параметров нейромодели можно отнести обобщение, обучаемость, интерпретабельность, надежность, распределенность памяти, вариативность и эффективность нейромоделей.

Обобщение — способность сети интегрировать частные данные для определения закономерностей и пролонгации результатов, что позволяет после обучения на одних данных применять полученные знания для других данных [7].

Коэффициент обобщения обученной сети определим как:

$$I_{gen} = \frac{NS}{N_w N_n} I_h \exp(-(E_{об.} - E_{тест.})^2),$$

где $E_{об.}$, $E_{тест.}$ — соответственно ошибка сети для обучающей и тестовой выборок.

Если коэффициент обобщения будет существенно больше единицы, то сеть проявляет большие обобщающие способности, если же коэффициент обобщения существенно меньше единицы, то сеть не проявляет обобщающих свойств.

Обучаемость — свойство нейросетей совершенствовать свою работу (обучаться или адаптироваться), используя примеры для настройки на решение определенной задачи [1, 7].

Определим показатель обучаемости сети как:

$$I_{lr} = \frac{I_{pl}(1-L)L_{net}}{NS},$$

где L_{net} — константа Липшица (сложность) нейронной сети net [2]; L — модифицированная константа Липшица для обучающей выборки:

— для задач с вещественной выходной переменной:

$$L(x, y) = \sqrt{\max_{\substack{s=1,2,\dots,S; \\ g=s+1,\dots,S}} \left\{ \frac{v_y (y^s - y^g)^2}{1 + \sum_{i=1}^N v_i (x_i^s - x_i^g)^2} \right\}}, \quad v_i = \left(\frac{1}{\max_{s=1,2,\dots,S} \{x_i^s\} - \min_{s=1,2,\dots,S} \{x_i^s\}} \right)^2,$$

$$v_y = \left(\frac{1}{\max_{s=1,2,\dots,S} \{y^s\} - \min_{s=1,2,\dots,S} \{y^s\}} \right)^2;$$

— для задач с дискретной выходной переменной:

$$L(x, y) = \left(1 + \min_{\substack{s=1,2,\dots,S; \\ g=s+1,\dots,S}} \left\{ \sum_{i=1}^N v_i (x_i^s - x_i^g)^2 \right\} \right)^{-0,5}.$$

Чем больше будет значение показателя обучаемости, тем большими возможностями обладает нейронная сеть net для решения задачи аппроксимации табличной заданной зависимости $y = f(x)$.

Интерпретабельность (логическая прозрачность) — свойство сети быть понятной для восприятия и анализа человеком [2]. Очевидно, что сеть является более интерпретабельной, если она иерархичная, функционально блочная, а также ее веса являются контрастными (близкими по значению к нулю или единице), причем среднее число входов нейрона не превышает 5–7 (это число обусловлено особенностями человеческой психики).

Наряду с ранее предложенными в [4, 5] характеристиками логической прозрачности можно эвристически определить интерпретабельность через иерархичность и функциональную блочность:

$$I_{\text{interp.}} = \frac{I_{fb} I_h N_n}{\sum_{\eta=1}^M \sum_{i=1}^{N_\eta} \sum_{j=1}^{N_{\eta-1}} \mathcal{G}_i(w_j^{(\eta,i)})}, \quad \mathcal{G}_i(w_j^{(\eta,i)}) = \begin{cases} 1 - |\sin(\pi w_j^{(\eta,i)})|, & 0 \leq w_j^{(\eta,i)} \leq 1, \\ \frac{1}{w_j^{(\eta,i)}}, & w_j^{(\eta,i)} > 1, \\ \frac{1}{|w_j^{(\eta,i)} - 1|}, & w_j^{(\eta,i)} < 0. \end{cases}$$

Надежность и устойчивость сети к отказам отдельных элементов, составляющих ее, проявляется в том, что отказ одного или нескольких нейроэлементов сети не приводит к отказу всей НС и не может существенно влиять на работу сети в целом [1].

Определим показатели надежности весов сети относительно обучающей выборки как:

$$I_{wre}^{avg} = 1 - \frac{\sum_{\eta=1}^M \sum_{i=1}^{N_\eta} \sum_{j=1}^{N_{\eta-1}} |E(w) - E(w|_{w_j^{(\eta,i)}=0})|}{N_w \sum_{i=1}^{N_M} |\Psi_{\max}^{(M,i)} - \Psi_{\min}^{(M,i)}|} \quad \text{и} \quad I_{wre}^{\max} = 1 - \frac{\max_{\substack{\eta=1,\dots,M; \\ i=1,\dots,N_\eta; \\ j=1,\dots,N_{\eta-1}}} |E(w) - E(w|_{w_j^{(\eta,i)}=0})|}{\max_{i=1,\dots,N_M} |\Psi_{\max}^{(M,i)} - \Psi_{\min}^{(M,i)}|},$$

где $E(w) = \sum_{s=1}^S \sum_{i=1}^{N_M} (y_i^s - \Psi_s^{(M,i)})^2$ — ошибка сети при наборе весовых коэффициентов w ; $\Psi_s^{(M,i)}$ — значение на i -м выходе сети для s -го экземпляра.

Определим показатели надежности нейронов сети относительно обучающей выборки как

$$I_{н.}^{avg} = 1 - \frac{\sum_{\eta=1}^M \sum_{i=1}^{N_{\eta}} \sum_{j=1}^{N_{\eta-1}} \left| E(w) - E(w |_{\forall p=1,2,\dots,N_{\eta+1}: w_i^{(\eta+1,p)}=0}) \right|}{N_w \sum_{i=1}^{N_M} \left| \Psi_{\max}^{(M,i)} - \Psi_{\min}^{(M,i)} \right|}$$

и

$$I_{н.}^{\max} = 1 - \frac{\max_{\substack{\eta=1,\dots,M; \\ i=1,\dots,N_{\eta}; \\ j=1,\dots,N_{\eta-1}}} \left| E(w) - E(w |_{\forall p=1,2,\dots,N_{\eta+1}: w_i^{(\eta+1,p)}=0}) \right|}{\max_{i=1,\dots,N_M} \left| \Psi_{\max}^{(M,i)} - \Psi_{\min}^{(M,i)} \right|}.$$

Распределенность памяти — информация в сети хранится по многим адресам, распределенным образом, так, что каждый элемент данных представляется шаблоном активности, распределенным по многим вычислительным элементам, и каждый вычислительный элемент участвует в представлении многих различных элементов данных [1, 2].

Распределенность памяти сети представим как усредненную долю весов, оказывающих существенное влияние на выход сети, в общем числе весов для обучающей выборки:

$$I_{md} = \frac{\sum_{s=1}^S \sum_{\eta=1}^M \sum_{i=1}^{N_{\eta}} \sum_{j=1}^{N_{\eta-1}} (1 - e^{-(E(w,x^s) - E(w,x^s |_{w_j^{(\eta,i)}=0}))^2})}{SN_w}.$$

Вариативность моделей аппроксимируемой зависимости по одной и той же таблице данных сетью заключается в том, что при неизменной структуре, но разных начальных значениях весов либо разных методах их настройки после обучения в общем случае может получиться несколько различных нейромоделей [2].

Определим абсолютный показатель вариативности моделей для сети:

$$I_v = \prod_{\eta=1}^M \prod_{i=1}^{N_{\eta}} \left(\mathcal{G}_v(\varphi^{(\eta,i)}) \mathcal{G}_v(\psi^{(\eta,i)}) \prod_{j=1}^{N_{\eta-1}} \mathcal{G}_v(w_j^{(\eta,i)}) \right),$$

где $\mathcal{G}_v(\varphi^{(\eta,i)})$, $\mathcal{G}_v(\psi^{(\eta,i)})$, $\mathcal{G}_v(w_j^{(\eta,i)})$ — соответственно показатели вариативности типов дискриминантных и активационных функций нейронов, а также значений весов в процессе обучения сети: если соответствующий элемент сети в процессе обучения может принимать только одно фиксированное состояние, то полагают $\mathcal{G}_v(element) = 1$, вариативность дискриминантных и активационных функций оп-

ределяется архитектурой сети и методом обучения; для весов вариативность предлагается оценивать по формуле: $\mathcal{Q}_v(w_j^{(\eta,i)})=1$, если вес является неизменным в процессе обучения; $\mathcal{Q}_v(w_j^{(\eta,i)}) = \text{round}\left(\frac{w_{j\max}^{(\eta,i)} - w_{j\min}^{(\eta,i)}}{\Delta w_j^{(\eta,i)}}\right)$, если вес может изменяться.

Здесь $w_{j\max}^{(\eta,i)}, w_{j\min}^{(\eta,i)}$ — соответственно, максимальное и минимальное возможные значения веса $w_j^{(\eta,i)}$; $\Delta w_j^{(\eta,i)}$ — минимально возможное изменение веса с учетом размера разрядной сетки ЭВМ.

Эффективность (качество) решения задач НС определяется точностью (ошибкой) решения задачи для обучающих и тестовых данных, простотой, логической прозрачностью и быстродействием полученной нейросетевой модели, а также затратами на построение нейросетевой модели (требования к аппаратным средствам, итерационность и затраты времени метода обучения).

Обобщенный показатель эффективности нейромодели на основе предложенных показателей определим как:

$$I_{ef} = I_{pl} I_{par} I_h I_{fb} I_{gen} I_{lr} I_{interp} (I_{wre}^{avg} + I_n^{avg}) \left(\frac{1 + 0,5(I_{po} + I_{apo})}{6} \right) e^{-E}.$$

Обобщенный показатель эффективности может быть использован как для сравнения нейромоделей и методов их синтеза, так и для оптимизации процесса построения нейромоделей.

Заключение

В работе решена актуальная задача автоматизации анализа свойств и сравнения нейросетевых моделей.

Научная новизна работы заключается в том, что впервые предложены модели расчета критериев, характеризующих свойства нейронных и нейро-нечетких сетей, что позволяет автоматизировать решение задачи анализа свойств и сравнения нейросетевых и нейро-нечетких моделей при решении задач диагностики и распознавания образов.

Работа выполнена как часть госбюджетной темы Запорожского национального технического университета «Информационные технологии автоматизации распознавания образов и принятия решений для диагностики в условиях неопределенности на основе гибридных нечеткологических, нейросетевых и мультиагентных методов вычислительного интеллекта».

1. Нейросетевые системы управления / В.А. Терехов, Д.В. Ефимов, И.Ю. Тюкин, В.Н. Антонов. — СПб.: Изд-во С.-Петербургского ун-та, 1999. — 265 с.

2. *Миркес Е.М.* Нейроинформатика: учеб. пособ. для студентов. — Красноярск: ИПЦ КГТУ, 2002. — 347 с.

3. *Субботин С.О.* Неітеративні, еволюційні та мультиагентні методи синтезу нечіткологічних і нейромережних моделей: Монографія / С.О. Субботін, А.О. Олійник, О.О. Олійник; під заг. ред. С.О. Субботіна. — Запоріжжя: ЗНТУ, 2009. — 375 с.
4. *Субботин С.А.* Методика и критерии сравнения моделей и алгоритмов синтеза искусственных нейронных сетей // *Радиоелектроніка. Інформатика. Управління.* — 2003. — № 2. — С. 109–114.
5. *Субботин С.А.* О сравнении нейросетевых моделей // *Нейроинформатика и ее приложения: Материалы XI Всероссийского семинара, 3–5 октября 2003 г.; под ред. А.Н. Горбаня, Е.М. Миркеса.* — Красноярск: ИВМ СО РАН, 2003. — С. 152–153.
6. *Нейрокомпьютер как основа мыслящих ЭВМ.* — М.: Наука, 1993. — 239 с.
7. *Головко В.А.* Нейронные сети: обучение, организация и применение: учеб. пособ. для вузов / *Общ. ред. А.И. Галушкина.* — М.: ИПРЖР, 2001. — 256 с.

Поступила в редакцию 28.08.2009