

8. Голикова, В. В. Оценка качества сборки двигателей внутреннего сгорания в ходе приемосдаточных испытаний [Текст] / В. В. Голикова, К. Н. Осипов, Е. Л. Первухина // Вестник КузГТУ – 2010. – №6 С. 40 – 45.
9. Кирьянов, К. Г. Оптимальная дискретизация экспериментальных данных для последующей цифровой обработки [Текст] / К. Г. Кирьянов // Вестник Нижегородского университета им. Н.И. Лобачевского – 2008. – С. 39 – 46.
10. Доценко, С. В. Методы информационной оптимизации систем и процессов [Текст] / С. В. Доценко. – Севастополь: СевНТУ, 2010 – 262 с.

У багатьох практичних випадках виникає задача генерації локальних оцінок точності апроксимації. У статті запропоновано метод локального оцінювання точності апроксимації мережею на базі гібридних нейроподібних елементів шляхом розширення її архітектури та впровадження двоетапної схеми навчання. Отримані результати застосовані також до інших популярних архітектур штучних нейронних і нейро-фаззи мереж

Ключові слова: локальне оцінювання точності, еволюційна оптимізація архітектури, підвищення надійності апроксимації

Во многих практических случаях возникает задача генерации локальных оценок точности аппроксимации. В статье предложен метод локального оценивания точности аппроксимации сетью на базе гибридных нейроподобных элементов путем расширения ее архитектуры и внедрения двухэтапной схемы обучения. Полученные результаты применимы также к другим популярным архитектурам искусственных нейронных и нейро-фаззи сетей

Ключевые слова: локальное оценивание точности, эволюционная оптимизация архитектуры, повышение надежности аппроксимации

УДК 004.032.26

ЛОКАЛЬНОЕ ОЦЕНИВАНИЕ ТОЧНОСТИ АППРОКСИМАЦИИ СЕТЬЮ НА БАЗЕ ГИБРИДНЫХ НЕЙРОПОДОБНЫХ ЭЛЕМЕНТОВ

С. В. Попов

Доктор технических наук, главный научный сотрудник*

E-mail: serge.popov@gmx.net

К. А. Шкуро

Аспирант*

E-mail: shkurokristina@gmail.com

*Проблемная научно-исследовательская лаборатория автоматизированных систем управления Харьковский национальный университет радиозлектроники пр. Ленина, 14, г. Харьков, Украина, 61166

1. Введение

Точность – важный аспект решения любой практической задачи. Часто именно по этому критерию, в первую очередь, и выбирают тот или иной метод решения [1], а затем уже рассматривают сложность модели, трудоемкость ее реализации, удобство использования, вычислительные затраты и т.д. Это и не удивительно, ведь именно точность в значительной мере определяет экономический эффект от внедрения новых методов моделирования, поэтому борьба за повышение точности ведется на всех этапах: от выбора модели до выбора эксплуатационных параметров при ее внедрении. При обучении с учителем точность является естественным критерием, отражающим, насколько качественно полученная модель аппроксимирует изучаемый реальный процесс, генерирующий обрабатываемые данные. Поэтому многие исследователи в этой области направляют свои усилия на создание новых моделей,

обеспечивающих повышение точности для различных классов задач.

Нейро-фаззи сети (и сеть на базе гибридных нейроподобных элементов не является исключением [2]) обычно генерируют точечные оценки аппроксимируемой зависимости. При этом чаще всего точность этих оценок определяется в среднем для всех возможных условий функционирования сети. Оценка точности производится на тестовой выборке и, если она является достаточно репрезентативной, считается, что в условиях последующей эксплуатации сети ее точность будет соответствовать полученной оценке [3]. Такой способ оценивания точности наименее трудоемок и оправдан в большинстве случаев, однако есть ситуации, когда этого недостаточно [4]. Например, точность аппроксимации может иметь явно выраженную неравномерность по всей выборке. Это характерно, в частности, для задач прогнозирования тренд-сезонных временных рядов, где точность мо-

жет существенно зависеть как от текущего среднего значения временного ряда, так и от фазы сезонной составляющей. Также возможна зависимость точности аппроксимации от значений входных, внутренних и выходных сигналов модели. Например, точность прогнозирования потребления электроэнергии зависит от прогнозов погодных условий, являющихся входными сигналами прогнозирующей модели.

И таких примеров много, что заставляет обратить более пристальное внимание на данный вопрос и изучить возможность разработки методов локального оценивания точности аппроксимации с помощью сети на базе гибридных нейроподобных элементов. Получение оценок точности для каждого конкретного наблюдения даст возможность пользователям принимать более взвешенные решения на основе получаемых оценок, оценивать риск возникновения ошибок в каждом конкретном случае и при необходимости обращаться к альтернативным методам, например, экспертным оценкам, для снижения риска.

2. Анализ литературы и постановка задачи

Методы локального оценивания точности можно разделить на две группы: нацеленные на определенный тип модели и моделинезависимые. Хотя методы первой группы и менее общие, но в большинстве случаев они имеют лучшее математическое обоснование и вероятностную интерпретацию.

Методы второй группы ввиду своей общности не могут использовать конкретную структуру аппроксимирующей модели, ее параметры и другие специфические факторы, они используют только такие общие для методов обучения с учителем факторы, как состав обучающей выборки и используемый моделью набор входных сигналов.

Многие моделинезависимые методы основываются на локальном обучении и свойствах пространства входных сигналов модели [5, 6]. Чаще всего находят ближайшие к текущему наблюдению примеры из тестовой выборки, вычисляется точность аппроксимации на этих примерах и оценка точности аппроксимации текущего наблюдения получается путем взвешенного суммирования вычисленных значений. Такой подход отличается простотой, но в то же время чувствителен к применяемой метрике, шуму во входных данных и типу применяемой модели. Также применяется локальный анализ чувствительности модели в области текущего наблюдения [7]. Если небольшие изменения входных значений в этой области приводят к большим изменениям выходной аппроксимированной оценки, то такая аппроксимация считается ненадежной. Другой подход заключается в изменении обучающей выборки в области текущего наблюдения путем введения или исключения из нее некоторых данных. Модели, обученные на видоизмененных выборках сравниваются между собой, и если результаты их работы в этой области данных сильно разнятся, то аппроксимация считается ненадежной. Также степень надежности локальной аппроксимации может быть связана с плотностью обучающих примеров в данной области входных данных: чем выше плотность, тем надежнее аппроксимация.

С другой стороны, когда аппроксимирующая модель основана на вероятностном подходе, бывает возможно расширить ее таким образом, что вместе с точечной аппроксимацией текущего наблюдения генерируется и мера достоверности, обычно в диапазоне $[0,1]$, где 0 соответствует наиболее ненадежной аппроксимации, 1 – наиболее надежной. В случае линейных моделей получение подобных оценок и построение доверительных интервалов достаточно хорошо изучено в теории математической статистики [8].

В случае нелинейных, в частности, нейросетевых, моделей построение таких оценок представляет собой более сложную задачу, для решения которой применяют несколько подходов. Одни из них основаны на линеаризации модели с помощью разложения в ряд Тейлора [9], другие же непосредственно расширяют нелинейную модель.

Некоторые работы посвящены расширению популярной архитектуры ИНС – многослойного персептрона [10, 11] путем введения дополнительного скрытого слоя и второго выходного нейрона, генерирующего оценку дисперсии $\hat{\sigma}$ прогноза \hat{y} текущего наблюдения. В [10] дополнительный скрытый слой получает сигналы только от входных узлов сети, а в [11] также и от основного скрытого слоя сети.

Рассмотренный подход может быть доработан и применен к сети на базе гибридных нейроподобных элементов. Сформулируем основные требования к разрабатываемому методу локального оценивания точности.

1. Метод не должен накладывать никаких ограничений на архитектуру сети, так как в ходе выполнения эволюционной настройки архитектуры по методу, предложенному в [12], может быть получена сеть произвольной топологии, содержащая любые синапсы из набора допустимых.

2. Оценивание точности должно выполняться по произвольному критерию, не зависящему от критерия обучения сети. Например, обучение может производиться по критерию среднеквадратичной ошибки, а оценивание точности – в процентах.

3. Оценивание должно выполняться независимо для каждого аппроксимируемого наблюдения.

4. Метод оценивания точности должен иметь возможность получать входные, внутренние и выходные сигналы аппроксимирующей модели, а также дополнительные внешние сигналы.

3. Архитектура сети для локального оценивания точности аппроксимации

По сути, поставленная задача локального оценивания точности аппроксимации, в свою очередь, также может быть сформулирована в виде задачи аппроксимации зависимости оценки точности от указанных в п. 4 сигналов, которая может быть решена с помощью сети на базе гибридных нейроподобных элементов и предложенных авторами ранее методов настройки ее архитектуры и параметров [12, 13]. При этом обучающим сигналом для такой сети могут стать реальные значения ошибок аппроксимации на проверочной выборке.

Полносвязная архитектура предлагаемой сети для простого случая с $n=3$ входными узлами и $m=2$ выходными узлами, а также одним дополнительным входным сигналом x_4 представлена на рис. 1.

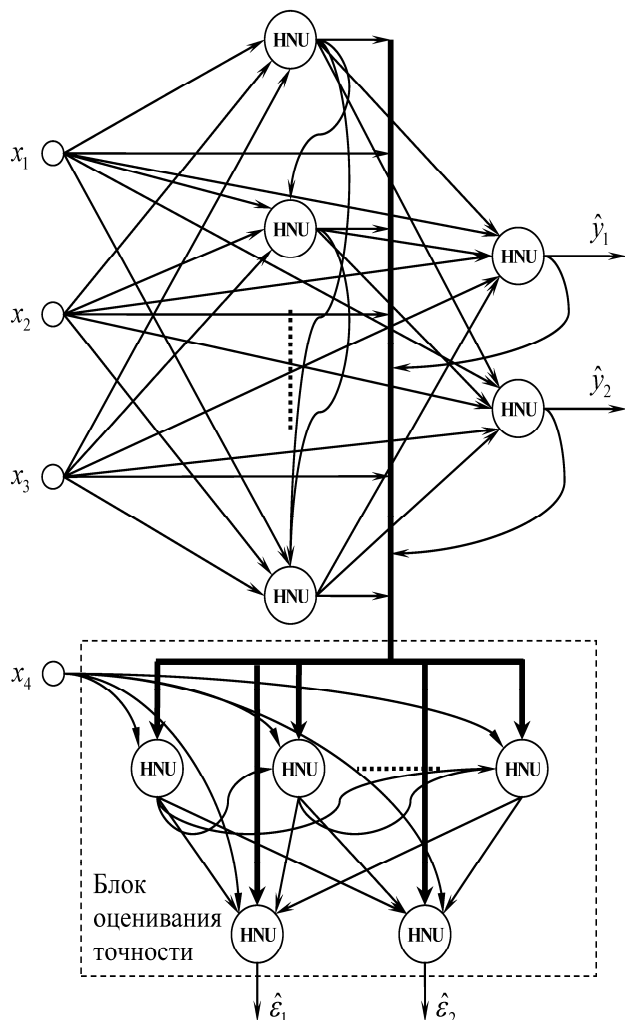


Рис. 1. Полносвязная архитектура сети на базе гибридных нейроподобных элементов с блоком оценивания точности

Создается такая сеть по следующей двухэтапной процедуре. На первом этапе генерируется основная сеть (без блока оценивания точности), выполняется ее структурная оптимизация и обучение для аппроксимации изучаемой зависимости

$$y(k) = \Phi(x(k)). \tag{1}$$

На этом этапе, имея обучающие сигналы $y(k)$ и выходные сигналы сети $\hat{y}(k)$, рассчитываются значения критерия точности аппроксимации $\epsilon(k)$ для каждого значения дискретного времени $k(k=1, \dots, N)$ на обучающей и проверочной выборках. Например, если критерием точности выбирается процентное значение абсолютной ошибки, то

$$\epsilon(k) = \frac{|y(k) - \hat{y}(k)|}{|y(k)|} \times 100\%. \tag{2}$$

На втором этапе фиксируется архитектура и параметры сети, полученные в ходе выполнения первого этапа, и к ней добавляется блок оценивания точности, входными сигналами которого становятся все входные, внутренние и выходные сигналы основной сети, а также дополнительные входные сигналы (при необходимости). Обучающим сигналом для блока оценивания точности становятся значения $\epsilon(k)$, полученные на проверочной выборке первого этапа. Выполняется настройка архитектуры и обучение блока оценивания точности (основная сеть при этом более не настраивается, а служит лишь источником сигналов).

После выполнения обоих этапов полученная сеть функционирует как единое целое. При подаче на вход сигналов $x_1(k), \dots, x_4(k)$ получаем на выходе аппроксимированные выходные значения $\hat{y}_1(k), \hat{y}_2(k)$ и оценки точности аппроксимации $\hat{\epsilon}_1(k), \hat{\epsilon}_2(k)$.

4. Структурная и параметрическая оптимизация сети для локального оценивания точности аппроксимации

Данная двухэтапная процедура может быть легко реализована с использованием предложенных ранее эволюционного метода настройки архитектуры [12] и метода параметрической оптимизации на основе Ψ -преобразования [13]. Первый этап полностью соответствует обычной схеме структурной и параметрической оптимизации сети на базе гибридных нейроподобных элементов.

На втором этапе необходимо определиться с количеством n^+ дополнительных входов, которые будут задействованы в блоке оценивания точности (на рис. 1 это единственный дополнительный вход x_4), а также максимально возможным количеством h^+ (допустим, $h^+ = 3$) скрытых узлов блока оценивания точности. Затем мы расширяем матрицу связности основной сети C , включая в нее дополнительные входные, скрытые и выходные узлы.

Так, если основная сеть имеет $n = 3$ входных узлов, $h = 5$ скрытых узлов, $m = 2$ выходных узла и полносвязную архитектуру, то количество синапсов в ней $N_s = 41$ и матрица связности C имеет следующий вид:

$$C = \begin{pmatrix} \times & \times & \times & S_1 & S_4 & S_8 & S_{13} & S_{19} & S_{26} & S_{34} \\ \times & \times & \times & S_2 & S_5 & S_9 & S_{14} & S_{20} & S_{27} & S_{35} \\ \times & \times & \times & S_3 & S_6 & S_{10} & S_{15} & S_{21} & S_{28} & S_{36} \\ \times & \times & \times & \times & S_7 & S_{11} & S_{16} & S_{22} & S_{29} & S_{37} \\ \times & \times & \times & \times & \times & S_{12} & S_{17} & S_{23} & S_{30} & S_{38} \\ \times & \times & \times & \times & \times & \times & S_{18} & S_{24} & S_{31} & S_{39} \\ \times & \times & \times & \times & \times & \times & \times & S_{25} & S_{32} & S_{40} \\ \times & \times & \times & \times & \times & \times & \times & \times & S_{33} & S_{41} \\ \times & \times & \times & \times & \times & \times & \times & \times & \times & \times \end{pmatrix}, \tag{3}$$

где S_l – синапсы;
 $l = 1, 2, \dots, N_s$;
 N_s – число синапсов основной сети, равное

$$N_s = \frac{h(h-1)}{2} + hn + hm + nm. \tag{4}$$

Синапс, находящийся на пересечении i -й строки и j -го столбца, соединяет выход i -го узла со входом j -го узла сети. Нумерация узлов последовательная: сначала n входных узлов, затем h скрытых узлов и m выходных узлов.

Так как рассматриваемая сеть предусматривает только прямую передачу информации, то связи с выхода любого узла на вход этого же узла (элементы главной диагонали матрицы связности C) и с выхода любого узла на вход любого предыдущего узла (элементы, лежащие ниже главной диагонали матрицы связности C) запрещены и отмечены в матрице символом \times . Также невозможны связи между входными узлами сети (элементы, лежащие в начале и выше главной диагонали матрицы связности C) и между выходными узлами сети (элементы, лежащие в конце и выше главной диагонали матрицы связности C).

Дополним C до матрицы связности расширенной (включая блок оценивания точности) сети C^+ , добавив строки и столбцы, соответствующие $n^+ = 1$ дополнительным входным узлам, $h^+ = 3$ скрытым узлам блока оценивания точности и $m^+ = 2$ выходным узлам блока оценивания точности.

Обратим внимание, что в данном случае $m^+ = m$ (по одному выходу блока оценивания точности на каждый выход основной сети), но это не обязательно должно быть так. В общем случае m^+ может выбираться произвольно и может быть как меньше m (оценивается точность не по всем выходам), так и больше m (точность по одному или нескольким выходам оценивается сразу по многим критериям).

Новые строки и столбцы добавляются, соответственно, в нижнюю и правую части матрицы связности, чтобы не нарушать нумерацию существующих синапсов: сначала идут n входных, h скрытых и m выходных узлов основной сети, затем n^+ входных, h^+ скрытых и m^+ выходных узлов блока оценивания точности.

Таким образом, матрица C^+ имеет вид:

$$C^+ = \begin{pmatrix} \times & \times & \times & S_1 & S_4 & S_8 & S_{13} & S_{19} & S_{26} & S_{34} & \times & S_{42} & S_{53} & S_{65} & S_{78} & S_{92} \\ \times & \times & \times & S_2 & S_5 & S_9 & S_{14} & S_{20} & S_{27} & S_{35} & \times & S_{43} & S_{54} & S_{66} & S_{79} & S_{93} \\ \times & \times & \times & S_3 & S_6 & S_{10} & S_{15} & S_{21} & S_{28} & S_{36} & \times & S_{44} & S_{55} & S_{67} & S_{80} & S_{94} \\ \times & \times & \times & \times & S_7 & S_{11} & S_{16} & S_{22} & S_{29} & S_{37} & \times & S_{45} & S_{56} & S_{68} & S_{81} & S_{95} \\ \times & \times & \times & \times & \times & S_{12} & S_{17} & S_{23} & S_{30} & S_{38} & \times & S_{46} & S_{57} & S_{69} & S_{82} & S_{96} \\ \times & \times & \times & \times & \times & \times & S_{18} & S_{24} & S_{31} & S_{39} & \times & S_{47} & S_{58} & S_{70} & S_{83} & S_{97} \\ \times & \times & \times & \times & \times & \times & \times & S_{25} & S_{32} & S_{40} & \times & S_{48} & S_{59} & S_{71} & S_{84} & S_{98} \\ \times & \times & \times & \times & \times & \times & \times & \times & S_{33} & S_{41} & \times & S_{49} & S_{60} & S_{72} & S_{85} & S_{99} \\ \times & \times & \times & \times & \times & \times & \times & \times & \times & \times & \times & S_{50} & S_{61} & S_{73} & S_{86} & S_{100} \\ \times & \times & \times & \times & \times & \times & \times & \times & \times & \times & \times & S_{51} & S_{62} & S_{74} & S_{87} & S_{101} \\ \times & \times & \times & \times & \times & \times & \times & \times & \times & \times & \times & S_{52} & S_{63} & S_{75} & S_{88} & S_{102} \\ \times & \times & \times & \times & \times & \times & \times & \times & \times & \times & \times & \times & S_{64} & S_{76} & S_{89} & S_{103} \\ \times & \times & \times & \times & \times & \times & \times & \times & \times & \times & \times & \times & \times & S_{77} & S_{90} & S_{104} \\ \times & \times & \times & \times & \times & \times & \times & \times & \times & \times & \times & \times & \times & \times & S_{91} & S_{105} \\ \times & \times & \times & \times & \times & \times & \times & \times & \times & \times & \times & \times & \times & \times & \times & \times \end{pmatrix}, \quad (5)$$

В итоге, полное количество возможных связей (синапсов) в расширенной сети составляет:

$$N_s^+ = N_s + \frac{h^+(h^+ - 1)}{2} + h^+(n + h + m + n^+ + m^+) + m^+(n + h + m + n^+). \quad (6)$$

Для выполнения эволюционной оптимизации архитектуры блока оценивания точности матрица связности C^+ преобразуется в хромосому G^+ :

$$G^+ = (g_1, g_2, \dots, g_{N_s^+}, \dots, g_{N_s^+}), \quad (7)$$

где g_i – гены, в свою очередь представленные векторами:

$$g_i = (p_1^0, \dots, p_1^4, p_1^S, p_1^W, S_1), \quad (8)$$

где p_1^0, \dots, p_1^4 – вероятности выбора соответствующего типа синапса в процессе эволюции, $p_1^0 + \dots + p_1^4 = 1$;

p_1^S – вероятность изменения структурных параметров синапса в процессе эволюции;

p_1^W – вероятность изменения синаптических весов синапса в процессе эволюции.

Путем задания нулевых значений среди p_1^0, \dots, p_1^4 можно запретить выбор определенных типов синапсов, например, запретить разрыв данной связи сети или запретить использование синапса-фильтра с бесконечной импульсной характеристикой, что позволяет избежать проблем с устойчивостью сети. Если же одну из вероятностей принять равной 1, то тем самым тип синапса будет жестко определен и не сможет изменяться. Обнулением p_1^S и p_1^W можно запретить структурную и параметрическую настройку синапса, соответственно. Тем самым, задавая вероятности P_1 и параметры синапсов S_1 на основе априорной информации о свойствах обрабатываемых сигналов и генерирующего их процесса, можно задать специализированную (частично предопределенную) архитектуру сети на базе гибридных нейродобных элементов.

Так как оптимизация архитектуры и параметрическая настройка основной части сети полностью выполнена на первом этапе и полученные значения не должны изменяться на втором, при задании вероятностей p_1^* и параметров синапсов S_1^* необходимо зафиксировать эти значения, что выполняется путем задания шаблона

$$\bar{G}^+ = (\bar{g}_1, \bar{g}_2, \dots, \bar{g}_{N_s^+}, \dots, \bar{g}_{N_s^+}), \quad (9)$$

определяющего неизменные свойства настраиваемой сети. Все генерируемые в ходе эволюционного процесса хромосомы G_i^{+q} будут ограничены данным шаблоном. В нем первые N_s генов задаются в соответствии с результатами первого этапа предлагаемой процедуры: параметры синап-

нов задаются в соответствии с результатами первого этапа предлагаемой процедуры: параметры синап-

сов S_k соответствуют полученным в ходе обучения значениям, вероятности P_1^0, \dots, P_1^4 выбираются в соответствии с результатами оптимизации архитектуры (все вероятности принимаются равными нулю, кроме той, которая соответствует нужному типу синапса и устанавливается равной единице), вероятности P_1^S и P_1^W обнуляются, тем самым запрещается структурная и параметрическая настройка этих синапсов.

Что касается генов $\bar{g}_{N_k+1}, \dots, \bar{g}_{N_k^*}$, задающих в шаблоне \bar{G}^+ ограничения на архитектуру и параметры блока оценивая точности, то здесь также возможно задавать вероятности P_1^* и параметры синапсов S_1 на основе априорной информации о свойствах обрабатываемых сигналов и генерирующего их процесса, тем самым добиваясь специализации этого блока сети на базе гибридных нейроподобных элементов.

На этапах настройки параметров основной сети и блока оценивания точности для уточнения координат экстремума функции ошибки $E(w)$ после получения оценки координат глобального экстремума методом Ψ - преобразования предлагается использовать модифицированную версию метода гравитационного поиска [14]. На этом этапе выполняется минимизация функции ошибки $E(w) \rightarrow \min$ по настраиваемым параметрам $w = (w_1, w_2, \dots, w_{N_p})^T$, где N_p - общее число параметров сети. Для уточнения координат экстремума используем N_w лучших точек, использованных для вычисления Ψ - преобразования, включая полученную оценку координат глобального экстремума \hat{w} .

В основе метода гравитационного поиска лежит понятие гравитационной силы $F^{ij}(t)$, действующей на текущей итерации t между любыми двумя поисковыми агентами w^i и $w^j, i \neq j$, представляющими собой точки в пространстве поиска:

$$F^{ij}(t) = g(t) \frac{M^i(t)M^j(t)}{R^{ij}(t) + \beta} (w^j(t) - w^i(t)), \quad (10)$$

где $g(t)$ - текущее значение гравитационной постоянной;

$M^i(t)$ - текущее значение массы агента w^i ;

$R^{ij}(t)$ - текущее евклидово расстояние между агентами w^i и w^j ;

β - небольшая положительная константа, ограничивающая силу $F^{ij}(t)$ при малых значениях $R^{ij}(t)$.

Массы агентов связаны со значениями функции ошибки:

$$\bar{M}^i(t) = \frac{E(w^i(t)) - E^{\min}(t)}{E^{\max}(t) - E^{\min}(t)}, \quad (11)$$

$$M^i(t) = \frac{\bar{M}^i(t)}{\sum_{j=1}^{N_w} \bar{M}^j(t)}, \quad (12)$$

где $E^{\max}(t)$ и $E^{\min}(t)$ - максимальное и минимальное значение ошибки среди всех агентов на текущей итерации, соответственно.

Для придания алгоритму стохастических свойств суммарная сила $F^i(t)$, действующая на агента w^i , определяется случайным взвешиванием сил, действующих от других агентов:

$$F^i(t) = \sum_{j=1, j \neq i}^{N_w} \text{rand}^j[0,1] F^{ij}(t), \quad (13)$$

где N_w - общее число агентов;

$\text{rand}^j[0,1]$ - случайная величина, равномерно распределенная в интервале $[0,1]$.

Затем рассчитывается ускорение агента w^i :

$$a^i(t) = \frac{F^i(t)}{M^i(t)},$$

после чего вычисляется новая скорость и новое положение всех агентов:

$$v^i(t+1) = \text{rand}^i[0,1] v^i(t) + a^i(t), \quad (15)$$

$$w^i(t+1) = w^i(t) + v^i(t+1), \quad (16)$$

Вычисления по формулам - выполняются для $t = 1, \dots, N_t$, где N_t - максимальное число итераций. При этом значение гравитационной постоянной уменьшается по мере увеличения числа итераций для улучшения сходимости алгоритма. Поиск завершается при достижении заданного числа итераций или, когда скорость лучшего агента не превышает заданную константу, в течение нескольких итераций подряд.

Рассмотренный метод обладает существенным недостатком. Поскольку гравитационная сила всегда притягивает агентов друг к другу, это делает невозможным исследование пространства поиска вне зоны, ограниченной текущим положением агентов. Для преодоления этого недостатка предлагается модифицировать метод гравитационного поиска, введя в него некоторые элементы комплекс-метода Бокса [15], а именно, на каждой итерации находить агента w^{\max} с максимальным значением ошибки $E^{\max}(t)$ и заменять его новым агентом w^{new} , производя отражение координат относительно центра тяжести всех агентов w^C

$$w^{\text{new}} = w^C + \alpha(w^C - w^{\max}), \quad (17)$$

где $\alpha > 1$ - коэффициент отражения.

5. Экспериментальные результаты

Для проверки работоспособности предложенного подхода, мы решили задачу 24-часового прогнозирования электрической нагрузки в Донбасской энергосистеме (ДЭС) Украины. Имеются почасовые данные за три года (в общей сложности 26280 наблюдений), которые разделены на три равные части: обучающую выборку (2005-й год), и две тестовые выборки (2006-й и 2007-й годы). Сеть получает следующие входные сигналы:

- количественные переменные:
 - текущее значение прогнозируемого процесса $u(k)$;
 - температура воздуха;
- порядковые переменные:
 - относительная влажность в форме «низкая - средняя - высокая»;
 - скорость ветра в форме «штиль - слабый - сильный - ураганный»;

- облачность в форме «ясно – переменная – плотная»;
- номер часа в сутках: 0, 1, 2, ..., 23;
- день недели в форме «понедельник – вторник – ... – воскресенье»;
- номинальные переменные:
 - тип дня в форме «рабочий – выходной – праздничный – региональный праздник – перенесенный выходной – перенесенный рабочий»;
 - тип погоды в форме «без осадков – туман – дождь – снег».

На первом этапе мы обучили основную сеть и вычислили прогнозы и ошибки прогнозирования на обеих тестовых выборках. На втором этапе мы обучили блок оценивания точности на первой тестовой выборке и оценили качество его работы на второй тестовой выборке. Фрагмент графика истинных значений ошибок и их оценок, сгенерированных сетью, на второй тестовой выборке показан на рис. 2.




Рис. 2. Зависимость ошибки ε от текущего шага k на второй тестовой выборке: сплошная линия — истинные значения ошибок, штриховая линия — оценки ошибок

Анализ графиков показывает, что предложенный метод оценивания достаточно точно воспроизводит форму графика ошибок, четко выделяя участки с высоким уровнем ошибок, требующие повышенного вни-

мания. Общее качество работы метода может быть оценено путем сравнения истинного и оцененного среднего значения ошибки по всей выборке. Эти значения составили 1.6188% и 1.6475%, соответственно, что указывает на высокое качество работы метода.

6. Выводы

Использование гибридных нейроподобных элементов позволяет перейти от методологии «черного ящика» к методологии «серого ящика» при построении искусственных нейронных и нейро-фаззи сетей за счет использования априорной информации в ходе синтеза их архитектуры. Существует и обратная связь: полученная в ходе эволюционной оптимизации специализированная архитектура сети может пролить свет на внутренние механизмы функционирования исследуемой системы, что важно при моделировании сложных реальных объектов. Добавление блока оценивания точности значительно расширяет эксплуатационные возможности сети за счет добавления к точечным аппроксимациям оценок их ожидаемой точности, что снижает уровень неопределенности в процессе дальнейшего принятия решений. Модифицированный метод гравитационного поиска, используемый при обучении предложенной сети, придает ей дополнительные возможности уточнения экстремума функции ошибки.

Предложенный метод локального оценивания точности аппроксимации является достаточно универсальным и может применяться ко многим популярным архитектурам ИНС, например, к многослойному персептрону, сети с конечной импульсной характеристикой и другим нейронным и нейро-фаззи сетям, являющимся частными случаями сети на базе гибридных нейроподобных элементов.

Литература

1. Kononenko, I. Machine Learning and Data Mining: Introduction to Principles and Algorithms [Текст] / Kononenko I., Kukar M. – Cambridge : Horwood Publishing, 2007. – 454 p.
2. Попов, С. В. Гибридный нейроподобный элемент – новый тип строительного блока искусственных нейронных сетей [Текст] / Попов С. В., Шкуро К. А. // Научный вестник Донбасской государственной машиностроительной академии. – 2011. – № 2(8E). – С. 87-92.
3. Haykin, S. Neural Networks. A Comprehensive Foundation [Текст] / Haykin S. – Upper Saddle River : Prentice Hall, 1999. – 842 p.
4. Statistical concepts in reliability [Текст] / Crowder M. J., Kimber A. C., Smith R. L., Sweeting T. J. // Statistical Analysis of Reliability Data – London: Chapman & Hall, 1991. – P. 1-11.
5. Schaal, S. Assessing the quality of learned local models [Текст] / Schaal S., Atkeson C. G. // Advances in Neural Information Processing Systems. – San Mateo, CA, 1994. – P. 160-167.
6. Birattari, M. Local Learning for Data Analysis [Текст] / Birattari M., Bontempi H., Bersini H. // Proc. 8th Belgian-Dutch Conference on Machine Learning. – Benelearn, 1998. – P. 55-61.
7. Rodrigues, P. P. Online Reliability Estimates for Individual Predictions in Data Streams [Текст] / Rodrigues P. P., Gama J., Bosnic Z. // Data Mining Workshops, 2008. ICDMW '08. IEEE International Conference on. – 2008. – P. 36-45.
8. Кобзарь, А. И. Прикладная математическая статистика [Текст] / Кобзарь А. И. – М. : ФИЗМАТЛИТ, 2006. – 816 с.
9. Rivals, I. Construction of confidence intervals for neural networks based on least squares estimation [Текст] / Rivals I., Personnaz L. // Neural Networks. – 2000. – Vol. 13, № 4-5. – P. 463-484.
10. Bishop, C. M. Regression with Input-Dependent Noise: A Bayesian Treatment [Текст] / Bishop C. M., Qazaz C. S. // Advances in Neural Information Processing Systems 9: Proceedings of the 1996 Conference. – Denver, 1997. – P. 347-353.

11. Nix, D. A. Learning Local Error Bars for Nonlinear Regression [Текст] / Nix D. A., Weigend A. S. // Advances in Neural Information Processing Systems: Proceedings of the 1994 Conference. – Denver, 1995. – P. 489-496.
12. Popov, S. Evolutionary Optimized Network of Hybrid Neuron-Like Units [Текст] / Popov S., Shkuro K. // Proc. 7th Int. Conf. Neural Networks and Artificial Intelligence (ICNNAI-2012). – Minsk, Belarus, 2012. – P. 32-35.
13. Попов, С. В. Метод параметрической оптимизации сети на базе гибридных нейроподобных элементов, основанный на методе Ψ -преобразования [Текст] / Попов С. В., Шкуро К. А. // Радиоелектронні і комп'ютерні системи. – 2013. – № 2(61). – С. 94-100.
14. Rashedi, E. GSA: A Gravitational Search Algorithm [Текст] / Rashedi E., Nezamabadi-pour H., Saryazdi S. // Information Sciences. – 2009. – Vol. 179, № 13. – P. 2232-2248.
15. Химмельблау, Д. Прикладное нелинейное программирование [Текст] / Химмельблау Д. – М.: Мир, 1975. – 536 с.

УДК 631.2:631.171:65.011.56

МОДЕЛЮВАННЯ ВПЛИВУ ТЕПЛОПРОВІДНОСТІ ЕЛЕКТРОНАГРІВАЛЬНОЇ СТРУКТУРИ НА ТЕПЛОВИЙ РЕЖИМ ЇЇ ПОВЕРХНІ

А. П. Слесаренко

Доктор фізико-математичних наук, професор
Лауреат Державної премії України
Ведучий науковий співробітник
Інститут проблем машинобудування
ім. А.М. Підгорного НАН України
вул. Дм. Пожарського, 2/10,
м. Харків, Україна, 61046

М. А. Романченко

Кандидат технічних наук, професор
Кафедра «Інтегровані електротехнології та процеси»
Харківський національний технічний університет
сільського господарства ім. Петра Василенка
вул. Енгельса 19, м. Харків, Україна, 61012

Запропоновано математичну модель впливу теплопровідності багатопшарової структури електротеплоаккумуляційної системи опалення гріючою підлогою виробничих тваринницьких споруд різного функціонального призначення, яка дозволяє на стадії проектних розробок отримати дані щодо геометричних і енергетичних характеристик теплогенеруючих установок, які формують стандарти заданих теплових режимів на поверхні багатоярусної електрообігрівної підлоги

Ключові слова: електротехнології, мікроклімат, автоматизація, теплопровідність, фізична модель

Предложена математическая модель влияния теплопроводности многослойной структуры энерготеплоаккумуляционной системы отопления обогреваемым полом производственных животноводческих помещений различного функционального назначения, которая позволяет на стадии проектных разработок получить данные геометрических и энергетических характеристик теплогенерирующих установок, которые формируют стандарты заданных тепловых режимов на поверхности многоярусного электрообогреваемого пола

Ключевые слова: електротехнологии, микроклимат, автоматизация, теплопроводность, физическая модель

1. Вступ

Одним із енергоємних секторів народного господарства України являється агропромисловий комплекс, в якому для забезпечення технологічних процесів виробництва сільськогосподарської продукції споживається біля 20% енергоносіїв вітчизняного енергоринку.

Саме енерговитрати на формування стандартних значень теплового режиму мікроклімату виробничих споруд, як домінуючого по енергоємності та інтенсивності фізіологічного впливу на життєдіяльність біооб'єктів тваринництва є одним із найбільш вагомих

негативних факторів зниження рентабельності виробництва цієї продукції.

2. Постановка проблеми

Перспективним напрямом інтенсифікації виробництва конкурентоспроможної екологічно чистої продукції тваринництва є створення енергозберігаючих, автоматизованих електротехнологічних комплексів для надійного децентралізованого забезпечення в них якісних показників мікроклімату. Мова йде про застосування технологій електротеплоаккумуля-