

Е.В. Бодянский, Е.А. Винокурова, П.П. Мулеса

Диагностирующая вэйвлет-нейро-фаззи-система с адаптивными вэйвлет-функциями принадлежности в задачах анализа многомерных данных

Предложена архитектура диагностирующей вэйвлет-нейро-фаззи-системы, построенной на основе системы Такаги-Сугено-Канга с нелинейным слоем диагностики, позволяющей решать задачу диагностирования-кластеризации. Введена модификация метода обучения диагностирующей вэйвлет-нейро-фаззи-системы, основанной на критерии распознавания образов, которая характеризуется повышенным быстродействием и простотой численной реализации.

Ключевые слова: диагностирование, вэйвлет-нейро-фаззи-система, вычислительный интеллект, *online*-обучение.

Запропоновано архітектуру діагностуючої вейвлет-нейро-фаззі-системи, побудованої на основі системи Такагі-Сугено-Канга з нелінійним шаром діагностики, що дозволяє розв'язати задачу діагностування-кластеризації. Введено модифікацію метода навчання діагностуючої вейвлет-нейро-фаззі-системи, побудованої на основі критерію розпізнавання образів, яка характеризується підвищеною швидкістю та простотою обчислювальної реалізації.

Ключові слова: діагностування, вейвлет-нейро-фаззі-система, обчислювальний інтелект, *online*-навчання.

Введение. Для решения широкого круга задач интеллектуального анализа данных большого объема (*Computational Intelligence, Big Data, Data Stream Mining*) [1–3], связанных прежде всего с диагностированием, классификацией, компрессией, распознаванием образов, все чаще используются искусственные нейронные сети [4] благодаря их универсальным аппроксимирующим свойствам и способности обучения по имеющимся экспериментальным данным. И хотя для решения подобных задач наибольшее распространение получил классический многослойный персептрон, нельзя не отметить такие его основные недостатки, как довольно большой объем обучающей выборки, низкую скорость сходимости процесса обратного распространения ошибок, необходимость использования большого количества эпох обучения. И если сугубо вычислительные проблемы можно обойти, необходимость репрезентативной обучающей выборки существенно усложняет использование этой нейронной сети при решении многих практических задач. Особенно остро эта проблема возникает в медико-биологических исследованиях, где выборка данных короткая и при этом объект описывается множеством разноплановых характеристик [5, 6].

В такой ситуации наиболее эффективны радиально-базисные нейронные сети [4], выходной сигнал которых линейно зависит от настраиваемых синаптических весов. Это обстоятельство позволяет использовать для обучения этих сетей арсенал известных подходов от стандартного метода наименьших квадратов до популярных алгоритмов линейной адаптивной идентификации [7]. И хотя специфика задач диагностирования-классификации ограничивает возможности использования традиционного квадратичного критерия обучения, применение специализированного критерия Дж. Шинка [8], ориентированного на задачи распознавания образов с двоичным обучающим сигналом, позволило синтезировать достаточно простую и эффективную диагностирующую радиально-базисную нейронную сеть [9, 10].

Несмотря на все преимущества, радиально-базисные сети все же не являются панацеей, поскольку их возможности ограничиваются так называемым «проклятием размерности», что ведет к экспоненциальному росту числа настраиваемых синаптических весов в зависимости от размерности пространства входных сигналов-образов.

Достаточно перспективно в данном случае использование вэйвлет-нейро-фаззи-систем, ко-

торые наряду с аппроксимирующими возможностями и способностью к обучению позволяют обеспечить лингвистическую интерпретацию результатов, а использование вэйвлет-функций принадлежности-активаций – обработать данные с локальными особенностями. Синтезу такой диагностирующей вэйвлет-нейро-фаззи-системы для ситуаций, когда размерность входных сигналов имеет один порядок с объемом обучающей выборки, а собственно данные поступают на вход системы в последовательном *online*-режиме, посвящена эта статья.

Архитектура диагностирующей вэйвлет-нейро-фаззи-системы

Архитектура системы приведена на рис. 1 и состоит из шести последовательно соединенных слоев. На входной (нулевой, рецепторный) слой нейро-фаззи-системы подается $(n \times 1)$ -мерный вектор входных сигналов-образов $x(k) = (x_1(k), x_2(k), \dots, x_n(k))^T$, где $k = 1, 2, \dots, N$ – номер наблюдения во входном массиве дан-




Рис. 1

ных. При этом подразумевается, что все компоненты $x_i(k)$ предварительно пронормированы так, что $0 \leq x_i(k) \leq 1, \forall i = 1, 2, \dots, n$, а двоичные входные признаки принимают значение ноль или единица.

Первый скрытый слой содержит nh вэйвлет-функций принадлежности-активаций $\mu_{li}(x_i(k))$, $i = 1, 2, \dots, n$; $l = 1, 2, \dots, h$ и выполняет фаззификацию входных переменных, при этом чем больше число h , тем лучше аппроксимирующие свойства нейро-фаззи-системы, хотя для двоичных признаков достаточно иметь $h = 2$.

Второй скрытый слой реализует агрегирование уровней принадлежности, вычисленных в первом слое, и состоит из h блоков умножения Π .

Третий скрытый слой – это слой синаптических весов w_{jl} , $j = 1, 2, \dots, m$, подлежащих обучению. Рассмотренная вэйвлет-нейро-фаззи-система содержит mh настраиваемых весов, где m

– количество возможных классов-диагнозов, по одному на каждый выход системы. Понятно, что $mh \ll e^n$, т.е. количество весов вэйвлет-нейро-фаззи-системы существенно меньше числа весов радиально-базисной нейронной сети.

Четвертый скрытый слой образован $m + 1$ сумматорами Σ , вычисляющими суммы сигналов на выходах второго и третьего скрытых слоев.

В *пятом* скрытом слое, образованном m блоками деления \bullet/\bullet , проводится нормализация выходных сигналов четвертого слоя.

И, наконец, *выходной (шестой)* слой содержит m нелинейных активационных функций, при этом в задачах диагностики целесообразно использование простейших сигнум-функций, принимающих

значения +1 в случае правильного диагноза и -1 – в другом случае. Таким образом, выходные сигналы системы $y_j(k)$ могут принимать только два значения ± 1 .

Так, при подаче на вход вэйвлет-нейро-фаззи-системы векторного сигнала $x(k)$, элементы первого слоя вычисляют уровни принадлежности $\mu_{li}(x_i(k))$, при этом в качестве функций принадлежности предлагается использование одномерной адаптивной вэйвлет-функции принадлежности-активации [11] в виде

$$\mu_{li}(x_i(k)) = (1 - \alpha_{li}(k)t_{li}^2(k)) \exp\left(-\frac{t_{li}^2(k)}{2}\right), \quad (1)$$

где $t_{li}(k) = \frac{x_i(k) - c_{li}(k)}{\sigma_{li}(k)}$, $c_{li}(k)$ – параметр центра, $\sigma_{li}(k)$ – параметр ширины, $\alpha_{li}(k)$ – параметр формы функций.

На рис. 2 представлены адаптивные вэйвлет-функции принадлежности-активации при разных параметрах.




Рис. 2

Параметр $\alpha_{li}(k)$ позволяет настройку формы адаптивной вэйвлет-функции принадлежности-активации в процессе обучения сети, при этом если $\alpha_{li}(k) = 0$, получаем Гауссову функцию (рис. 2, а), если $\alpha_{li}(k) = 1$, получаем вэйвлет-функцию *Mexican Hat* (рис. 2, б), а если $0 < \alpha_{li}(k) < 1$ – гибридную функцию принадлежности-активации (рис. 2, в).

Заметим, что функции принадлежности (1) в ряде случаев с успехом могут быть использованы и для признаков, принимающих произвольное количество значений, а число настраиваемых синаптических весов принимает минимально возможное значение $2m$.

На выходах второго скрытого слоя появляются агрегированные значения $\prod_{i=1}^n \mu_{li}(x_i(k))$, когда несложно увидеть, что, если параметры ширины σ_i одинаковы для всех признаков, т.е. $\sigma_i = \sigma$, то

$$\prod_{i=1}^n \mu_{li}(x_i(k)) = \prod_{i=1}^n (1 - \alpha_{li}(k)t_{li}^2(k)) \exp\left(-\frac{t_{li}^2(k)}{2}\right), \quad (2)$$

(здесь $c_l = (c_{l1}, c_{l2}, \dots, c_{ln})^T$), т.е. реализуется нелинейное преобразование, аналогичное радиально-базисной нейронной сети.

Выходами третьего скрытого слоя будут сигналы $w_{jl} \prod_{i=1}^n \mu_{li}(x_i(k))$, четвертого – $\sum_{l=1}^h w_{jl} \times \prod_{i=1}^n \mu_{li}(x_i(k))$ и $\sum_{l=1}^h \prod_{i=1}^n \mu_{li}(x_i(k))$, пятого –

$$u_j(k) = \frac{\sum_{l=1}^h w_{jl} \prod_{i=1}^n \mu_{li}(x_i(k))}{\sum_{l=1}^h \prod_{i=1}^n \mu_{li}(x_i(k))} = \sum_{l=1}^h w_{jl} \frac{\prod_{i=1}^n \mu_{li}(x_i(k))}{\sum_{l=1}^h \prod_{i=1}^n \mu_{li}(x_i(k))} =$$

$$= \sum_{l=1}^h w_{jl} \varphi_l(x(k)) = w_j^T \varphi(x(k)), \quad (3)$$

здесь $\varphi_l(x(k)) = \prod_{i=1}^n \mu_{li}(x_i(k)) \left(\sum_{l=1}^h \prod_{i=1}^n \mu_{li}(x_i(k)) \right)^{-1}$,
 $w_j = (w_{j1}, w_{j2}, \dots, w_{jh})^T$, $\varphi(x(k)) = (\varphi_1(x(k)), \varphi_2(x(k)), \dots, \varphi_h(x(k)))^T$ и, наконец, шестого –
 $y_j(k) = \text{sign } u_j(k)$. (4)

Очевидно, что рассмотренная нейро-фаззи-система – это модификация системы Л. Ванга–Дж. Менделя [12] и ориентирована на решение задач *online* диагностики-классификации.

Обучение диагностирующей вэйвлет-нейро-фаззи-системы

Для обучения синаптических весов введенной системы используем метод обучения, основанный на специализированном критерии [8], предназначенном для решения задач распознавания образов, классификации, диагностики.

Введем в рассмотрение m ошибок обучения $e_j(k) = d_j(k) - y_j(k) = d_j(k) - \text{sign } u_j(k)$ (5)

и m критериев, основанных на этих ошибках $E_j(k) = e_j(k)u_j(k) = d_j(k)u_j(k) - |u_j(k)| =$
 $= (d_j(k) - \text{sign } w_j^T \varphi(x(k))) w_j^T \varphi(x(k))$, (6)

где $d_j(k) \in \{-1, 1\}$ – обучающий сигнал, принимающий значение единица, если входной вектор $x(k)$ принадлежит к j -му диагнозу, и – единица в другом случае.

Для настройки синаптических весов используем стандартную градиентную процедуру минимизации критерия (6)

$$w_{ji}(k+1) = w_{ji}(k) - \eta(k) \frac{\partial E_j(k)}{\partial w_{ji}},$$

(здесь $\eta(k)$ – параметр шага обучения), которая в векторной форме может быть переписана в виде $w_j(k+1) = w_j(k) + \eta(k) e_j(k) \varphi(x(k)) =$
 $= w_j(k) + \eta(k) (d_j(k) - \text{sign } w_j^T \varphi(x(k))) \cdot \varphi(x(k))$, (7)
 $j = 1, 2, \dots, m$.

Вводя далее обобщенный критерий для всех выходов системы

$$E(k) = \sum_{j=1}^m E_j(k) = \sum_{j=1}^m e_j(k) u_j(k),$$

можно записать алгоритм обучения всех синаптических весов системы в виде

$$W(k+1) = W(k) + \eta(k) (d(k) - \text{sign } W(k) \varphi(x(k))) \varphi^T(x(k)), \quad (8)$$

где

$$\text{sign}(u_1(k), u_2(k), \dots, u_m(k))^T = (\text{sign } u_1(k), \text{sign } u_2(k), \dots, \text{sign } u_m(k))^T,$$

$$d(k) = (d_1(k), d_2(k), \dots, d_m(k))^T,$$

$$W(k) = \begin{pmatrix} w_1^T(k) \\ w_2^T(k) \\ \vdots \\ w_m^T(k) \end{pmatrix} - (m \times h) \quad \text{– матрица настраи-}$$

ваемых синаптических весов.

Известно, что градиентные алгоритмы типа (7), (8) обеспечивают сходимость в достаточно широком диапазоне варьирования параметра шага $\eta(k)$, однако при этом скорость сходимости может оказаться недостаточной. Увеличить эту скорость можно, воспользовавшись квазиньютоновскими процедурами обучения [13], например,

$$w_j(k+1) = w_j(k) + (\varphi(x(k)) \varphi^T(x(k)) + \eta I)^{-1} e_j(k) \varphi(x(k)), \quad (9)$$

где $\eta > 0$ – регуляризирующий параметр, I – $(h \times h)$ – единичная матрица.

Воспользовавшись далее леммой обращения матриц, несложно показать, что [10]

$$(\varphi(x(k)) \varphi^T(x(k)) + \eta I)^{-1} \varphi(x(k)) = \frac{\varphi(x(k))}{\eta + \|\varphi(x(k))\|^2},$$

и переписать (9) в компактной форме

$$w_j(k+1) = w_j(k) + \frac{e_j(k) \varphi(x(k))}{\eta + \|\varphi(x(k))\|^2} \quad (10)$$

или

$$W(k+1) = W(k) + \frac{d(k) - \text{sign } W(k) \varphi(x(k))}{\eta + \|\varphi(x(k))\|^2} \varphi^T(x(k)), \quad (11)$$

которая при $\eta = 0$ будет многомерным вариантом оптимального по быстродействию алгоритма обучения, введенного в [14].

Предложенная диагностирующая нейро-фаззи-система и адаптивный метод ее обучения предназначены для решения задач распознавания образов, классификации, диагностики в условиях, когда объем обучающей выборки близок к размерности входных образов, а именно эти образы поступают на обработку последовательно в *online* режиме. Особенностью предложенной системы является существенно меньшее количество настраиваемых параметров в сравнении с нейронными сетями, которые решают ту же задачу.

Система характерна простотой численной реализации, высоким быстродействием при обучении, возможностью обработки информации, задаваемой в разных шкалах (количественной, ранговой, бинарной), что часто возникает в задачах интеллектуальной обработки медицинских данных.

Имитационное моделирование диагностирующей нейро-фаззи-системы и ее метода обучения

Диагностирование-классификация как один из видов задач интеллектуального анализа данных – это отдельный случай задачи аппроксимации, решаемой нейронными сетями, состоящими в построении отображения $R^n \rightarrow R^m$. Однако в случае диагностирования-классификации набор значений элементов входного множества ограничен количеством диагнозов. В качестве тестовой была решена задача диагностирования-классификации опухоли молочной железы.

Для этого была использована выборка, состоящая из 699 наблюдений [15]. 16 наблюдений содержали параметры с пропущенными значениями и были удалены из выборки, а оставшиеся 683 наблюдения были разделены на обучающую выборку – 478 наблюдений (70 процентов) и тестовую выборку – 205 наблюдений (30 процентов).

Каждое наблюдение содержало девятимерный вектор параметров и один параметр принадлежности к диагнозу (один или ноль), ко-

торый необходимо было определить, диагностируя тем самым злокачественную или доброкачественную опухоль.

Для сравнения: задача решалась четырьмя подходами – с помощью диагностирующей вэйвлет-нейро-фаззи-системы, каскадной нео-фаззи нейронной сети, нео-фаззи нейронной сети, каскадно-корреляционной нейронной сети и многослойного персептрона.

Диагностирующая вэйвлет-нейро-фаззи-система содержала шесть функций принадлежности в каждом нелинейном синапсе и настройка синаптических весов проводилась согласно предложенному алгоритму.

Для решения задачи было введено два критерия качества:

- количество корректно классифицированных образов;
- так называемый «доверительный интервал».

Очевидно, что если на выходе нейронной сети имеется значение, близкое к значению одного из классов, то вероятность корректной классификации будет иметь большее значение. Поскольку в рассмотренной задаче имеем только два класса (доброкачественная опухоль – 1, злокачественная опухоль – (-1)), то если выходной сигнал лежал в промежутке $[0,3; -0,3]$, считалось, что такой образ не попадает в доверительный интервал. Полученные результаты с учетом обоих критериев качества приведены в таблице.

Результаты диагностирования-кластеризации на основе диагностирующей вэйвлет-нейро-фаззи-системы

Нейронная сеть	Точность на обучающей выборке, %	Точность на тестовой выборке, %
Диагностирующая вэйвлет-нейро-фаззи-система	99,6	98
Каскадная нео-фаззи нейронная сеть	98,6	97
Каскадно-корреляционная нейронная сеть	95	94
Многослойный персептрон, 25 эпох	99,2	98,5
Нео-фаззи нейронная сеть	97,1	96,6

Как видим, наилучшие результаты показали диагностирующая вэйвлет-нейро-фаззи-системы и многослойный персептрон. Точность классификации этих двух архитектур практически идентична. В каскадной нео-фаззи нейронной

сети было синтезировано три каскада, а каждый нелинейный синапс нео-фаззи нейрона содержит по четыре треугольных функции принадлежности. Для настройки синаптических весов многослойного персептрона понадобилось значительно больше времени (приблизительно в 10 раз), чем в случае обучения диагностирующей вэйвлет-нейро-фаззи-системы.

Каскадно-корреляционная нейронная сеть показала наихудший результат. Обучение этой сети проводилось с использованием градиентного метода для каждого каскада, состоявшего из единственного элементарного персептрона Розенблатта. Очевидно, что в этом случае время обучения весовых коэффициентов, обусловленное низкой скоростью сходимости градиентного метода, было более продолжительным.

Заключение. Предложенная архитектура многослойной диагностирующей вэйвлет-нейро-фаззи-системы, построенная на основе системы Такаги–Сугено–Канга с нелинейным слотом диагностики с адаптивными вэйвлет-функциями принадлежности, позволяет решить задачу диагностирования-кластеризации. Модифицированный метод обучения такой системы, построенный на основе критерия распознавания образов, характеризуется повышенным быстродействием и простотой вычислительной реализации. Теоретические результаты проиллюстрированы экспериментами на тестовых выборках и подтверждают преимущества предложенного подхода.

1. *Bifet A.* Adaptive Stream Mining: Pattern Learning and Mining from Evolving Data Streams. – Amsterdam: IOS Press, 2010. – 218 p.
2. *Springer Handbook of Computational Intelligence* / Eds. J. Kacprzyk, W. Pedrycz. – Berlin–Heidelberg: Springer-Verlag, 2015. – 1634 p.
3. *Computational Intelligence: A Methodological Introduction* / R. Kruse, C. Borgelt, F. Klawonn et al. – Berlin: Springer-Verlag, 2013. – 488 p.

4. *Haykin S.* Neural Networks. A Comprehensive Foundation. – N.J., Upper Saddle River: Prentice Hall, Inc, 1999. – 842 p.
5. *Rizzo R.* Computational Intelligence Methods for Bioinformatics and Biostatistics / Lecture Notes in Bioinformatics (7th Int. Meeting, CIBIB 2010, Palermo, Italy, Sept. 16–18, 2010). – Springer-Verlag, 2011. – 301 p.
6. *Kountchev R., Iantovics B.* Advances in Intelligent Analysis of Medical Data and Decision Support Systems (Studies in Computational Intelligence). – Switzerland: Springer-Verlag, 2013. – 246 p.
7. *Ljung L.* System Identification: Theory for the User. – N.J., Upper Saddle River: PTR Prentice Hall, 1999. – 672 p.
8. *Shynk J.J.* Performance surfaces of a single-layer perceptron // IEEE Trans. on Neural Networks. – 1990. – 1, Issue 3. – P. 268–274.
9. *Бодянский Е.В., Кучеренко Е.И., Чапланов А.П.* Диагностика и прогнозирование временных рядов с помощью многослойной радиально-базисной нейронной сети // Труды 8 Всерос. конф. с междунар. участием «Нейрокомпьютеры и их применение». – М.: Ин-т проблем управл. им. В.А. Трапезникова РАН (21–22 марта 2002). – С. 209–213.
10. *Бодянский Е.В., Кучеренко Е.И., Михалев А.И.* Нейро-фаззи сети Петри в задачах моделирования сложных систем. – Днепропетровск: Системные технологии. – 2005. – 311 с.
11. *Bodyanskiy Ye., Vynokurova O.* Hybrid adaptive wavelet-neuro-fuzzy system for chaotic time series identification // Inform. sci. – 2013. – **220**. – P. 170–179.
12. *Wang L.-X.* Adaptive Fuzzy Systems and Control: Design and Stability Analysis. – N.J.: Prentice Hall, 1994. – 256 p.
13. *Shepherd A.J.* Second-Order Methods for Neural Networks. – London: Springer-Verlag, 1997. – 145 p.
14. *Цыпкин Я.З.* Основы теории обучающихся систем. – М.: Наука, 1970. – 252 с.
15. *Murphy P.M., Aha D.W.* UCI Repository of machine learning databases. – URL: <http://www.ics.uci.edu/mllearn/MLRepository.html>. CA: University of California, Depart. of Inform. and Comp. Sci., 1994.

Поступила 30.12.2015

E-mail: olena.vynokurova@nure.ua, yevgeniy.bodyanskiy@nure.ua
© Е.В. Бодянский, Е.В. Винокурова, П.П. Мулеса, 2016

UDC 004.032.26

Bodyanskiy Ye.V., Vynokurova O.A., Mulesa P.P.

Diagnosis Wavelet-Neuro-Fuzzy System with Adaptive Wavelet Membership Function for Big Data Analysis Tasks

Keywords: diagnosis, wavelet-neuro-fuzzy-system, computational intelligence, online learning.

The synthesis of the diagnostic wavelet-neuro-fuzzy system (WNFS) is used for the case, when training set volume is comparable with input patterns dimension. These patterns are fed for processing in on-line mode. An architecture of consid-

ered NFS consists of the six sequentially-connected layers. In the input (zero, receptive) layer of NFS ($n \times 1$)-dimensional vector of input signals-patterns $x(k) = (x_1(k), x_2(k), \dots, x_n(k))^T$ is fed, where $k = 1, 2, \dots, N$ is observation number in initial data set. In this case, it is supposed that all components $x_i(k)$ preliminary are modified so that $0 \leq x_i(k) \leq 1$, $\forall i = 1, 2, \dots, n$, and the binary input features have value 0 or 1. The first hidden layer consists of nh membership function $\mu_{li}(x_i(k))$, $i = 1, 2, \dots, n$; $l = 1, 2, \dots, h$ and provides fuzzyfication of input variables, the larger the number h , the better approximating properties of WNFS, although it is enough to have $h = 2$ for the binary features. The second hidden layer realizes an aggregation of the membership levels, which are computed in the first layer, and consists of h multiplication units. The third hidden layer is one of the synaptic weights w_{jl} , $j = 1, 2, \dots, m$ which are adjusted during the learning process. The proposed WNFS consists of mh tuning weights, where m is a number of the potential classes, one for each system output. It is clear, that $mh \ll e^n$, i.e. number of WNFS weights are significantly smaller than the number of RBFN weights. The fourth hidden layer consists of $m + 1$ summators, which compute sum of output signal of the second and the third hidden layers. In fifth hidden layer, that consists of m division unit normalization of fourth layer output signals is realized. And finally output (sixth) layer consists of m non-linear activation functions, in diagnosis tasks it is reasonable to use the simplest signum-functions, which takes $+1$ value in case of right diagnosis, and -1 – otherwise. Therefore output system signals $y_j(k)$ can take only two values ± 1 . Thus, if vector signal $x(k)$ is fed on NFS input, the first layer elements compute membership levels $\mu_{li}(x_i(k))$, at that usually the bell-shaped (kernel) construction with as membership function non-strictly local receptive field is used as membership functions. It allows to avoid the appearing of “gaps” in fuzzyficated space.

The diagnostic wavelet neuro-fuzzy system and its adaptive learning algorithm are introduced for solving the pattern recognition, classification, diagnostics tasks etc., under condition when training set value is comparable with input patterns dimension, and these patterns are fed for processing in on-line mode. The feature of proposed systems is significant smaller number of the tuning parameters comparing with the artificial neural networks that solve the same task. The system is characterized by simplicity of the computational implementation, the high speed of learning process, possibility of processing information, which is described in the different scales (interval, ordinal, binary).



Вниманию читателей

На сайте usim.irtc.org.ua выставлен архив журнала с 2009 года.

Авторы могут приобрести любой из имеющихся в редакции журналов, оплатив через расчетный счет Международного Центра текущую стоимость журнала.

Можно также оформить ретро-подписку через агентство «Укринформнаука»:
(тел. (044) 239-64-57, (044) 239-65-89, e-mail: innovation@nas.gov.ua).

Для продвижения журнала в международный научно-метрических базах, редакция в обязательном порядке должна иметь информацию об авторах статей на англ. языке: ФИО, должность, место работы, ученая степень, звание, контактная информация.