

Синтез нейросетевой модели для прогнозирования термических процессов электроизоляционных материалов силовых кабелей

Н.К. Полуянович, Н.В. Азаров, А.В. Огреничев, М.Н. Дубяго, А.А. Шурыкин

Южный федеральный университет, Ростов-на-Дону

Аннотация: В работе рассматриваются результаты исследования и анализа термических процессов в электроизоляционных материалах кабельных линий (КЛ). Показано, что искусственная нейронная сеть (ИНС) может применяться в решении задачи прогноза температурного режима токоведущей жилы. Точность прогнозирования составила 2,5% от фактической температуры на жиле КЛ. Анализ полученных результатов и их сравнение с прогнозируемыми результатами, допускают говорить об адекватности разработанной модели сети, а также о ее использовании на практике для надежной работы кабельной системы электроснабжения потребителей. Рассмотрено перспективное направление прогнозирования термических процессов в кабельных линиях распределительных систем электроснабжения для обеспечения их надежной работы.

Ключевые слова: Нейронные сети, термофлуктуационные процессы, изоляционные материалы, архитектура нейронной сети.

Введение и постановка задачи

Нагрузочная способность кабельных систем (КС) электроснабжения потребителей является основной характеристикой. Нагрузочная способность зависит от теплового режима работы, по которому и определяется сечение силового кабеля и его допустимая нагрузка [1].

Одним из решений указанной задачи является мониторинг температуры поверхности кабеля в динамическом режиме. Таким образом, задача, поставленная в работе, нацелена на разработку интеллектуальной нейросети позволяющей осуществлять не только мониторинг термических процессов в изоляционных материалах КС, но и их прогноз [2]. Как видно из литературных источников, высокоперспективным представляется метод искусственных нейронных сетей (ИНС). Для обучения нейронной сети (НС) возможно использование открытых баз данных мониторинга энергетических систем.

Разработка тепловой схемы замещения СКЛ

Ресурс изоляционных материалов силовых кабельных линий (СКЛ) зависит от ее температуры, тока жилы и экрана, влажности [3]. Поэтому текущая информация о температурном поле в кабельной линии (рис.1, а) является актуальной задачей. Известно, что основная изоляция кабеля (рис.1), имеет небольшую теплопроводность. Это обстоятельство приводит к большому температурному градиенту по сечению кабеля. В связи с этим распределение температур по сечению (рис.1, а), температура на поверхности $\theta_{з.о}$ и у жилы $\theta_{ж}$, кабеля сильно различается [6].

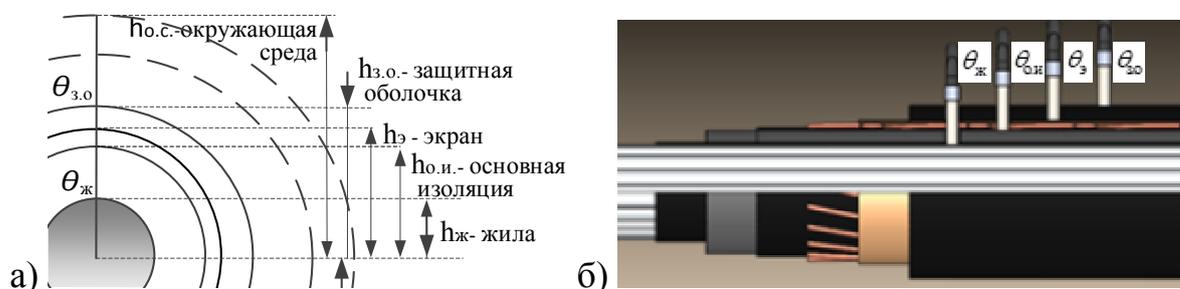


Рис. 1 Исследуемый кабель: а–сечение кабеля; б– послойная установка датчиков.

Разработка НС продиктована следующими обстоятельствами:

- возможностью мониторинга и расчета процесса передачи тепла через изоляционные слои (рис.1, б), при сложном изменении температуры жилы [4];
- сбором, анализом температурных данных в зависимости от изменений токовой нагрузки линии и внешних условий теплоотвода [5].

Поэтому, задача создания НС для диагностики и прогнозирования термических процессов, оценки пропускной способности СКЛ в динамическом режиме ее работы является актуальной.

Ток кабельной линии определяется многими факторами [7]

$$I_{\text{доп}} = f(n, \theta_{ж}, \theta_{с}, \tau, S, R, P_u)$$

где $\theta_{ж}$ – температура нагрева жилы кабеля, °C; n – число жил, шт; θ_c – температура окружающей среды, °C; S – тепловое сопротивление кабеля и окружающей среды, град см/Вт; P_n – мощность диэлектрических потерь в изоляции, Вт; R – сопротивление жилы, Ом.

Синтез конфигурации ИНС

Для решения поставленной задачи были проанализированы различные типы ИНС [8,9]. Эффективность работы НС определялась по среднеквадратичной ошибке. Ошибка определялась на основе прогнозируемых и экспериментальных данных как обучающей, так и тестовой выборки по формуле:

$$E = \frac{1}{N * K} \sum_{i=1}^K \sum_{j=1}^N (y_{ij}^{реал} - y_{ij}^{прогн})^2$$

где $y_{ij}^{прогн}$ - прогнозируемое значение i -й выходной переменной НС для j -го обучающего или тестового примера; $y_{ij}^{реал}$ – значение i -й выходной переменной НС для j -го обучающего или тестового примера; K – количество выходных переменных НС; N – количество примеров в обучающей или тестовой выборке. Полученные результаты сравнение типов НС представлены в таблице № 1.

Таблица № 1

Результаты сравнения НС

№ п.п	Тип нейронной сети	Средняя ошибка прогноза	
		ϵ , °C	ϵ , %
1	Многослойный перцептрон (MLP) / Multilayered perceptron (MLP)	0,9	2,3
2	Рекуррентная нейронная сеть (Layer recurrent)	1,2	2,5
3	Каскадная сеть прямого распространения (cascade forward backpropagation)	1,63	4,2

4	Сеть Эльмана с обратным распространением ошибки (Elman backpropagation)	2,14	5,3
5	Сеть с запаздыванием и обратным распространением ошибки (backpropagation with delay)	2,75	7,4

Таким образом, анализ результатов сравнения НС показал, что наименьшую ошибку прогноза имеет многослойный персептрон; на втором месте находится рекуррентная НС; самой низкой точностью обладает сеть с запаздыванием и обратным распространением ошибки.

Синтез структуры НС

В ходе исследований термических процессов в кабеле (рис.1) были сняты многочисленные данные. Исходные данные обучающей выборки представляют собой:

- ток протекающий по жиле;
- температуру поверхности кабеля;
- температуру окружающей среды.

База данных, используемая для обучения разработанной сети, включает в себя обучающую (прогнозная модель кабеля без повреждений) и контрольную (для оценки прогнозной модели при поврежденной изоляции кабеля) [10].

Для прогнозирования температуры жилы СКЛ разработана НС представляющая собой многослойный персептрон с прямым распространением сигнала [9]. Активационная функция представляет собой гиперболический тангенс $f(x) = (e^x - e^{-x}) / (e^x + e^{-x})$. Сеть обучается каждый раз «с нуля», весовые коэффициенты полученные при первичном обучении сети не используются для повторного обучения. Входными параметрами НС являются члены временного ряда $X(n)$ такие как: $\theta_{з.о}(1...n)$ – температура защитной оболочки, $\theta_{о.с}(1...n)$ – температура окружающей среды, $I_{ж}(1...n)$ – ток в жиле СКЛ. НС содержит n нейронов распределительного слоя, L нейронов скрытого слоя и выходной слой m ,

содержащий один нейрон. В соответствии со структурой имеется две матрицы весов: скрытого слоя v размером $i \times j$ и выходного слоя w размером $j \times k$. Прямой ход алгоритма обратного распространения ошибки в процессе обучения описывается в виде:

$$g_j = f\left(\sum_{i=1}^n v_{ij} x_i + Q_j\right)$$

$$y_k = f\left(\sum_{j=1}^h w_{kj} g_j + T_k\right)$$

Где g_j – сигнал на выходе нейронов скрытого слоя, y_k – сигнал на выходе нейронов выходного слоя.

Проведем описание обратного хода алгоритма обратного распространения ошибки:

Изменение весовых коэффициентов и порогов НС происходит по следующим формулам:

$$w_{jk}(t+1) = w_{jk}(t) + a \frac{\partial E}{\partial w_{jk}(t)} \quad (1)$$

$$T_k(t+1) = T_k(t) + a \frac{\partial E}{\partial T_k(t)} \quad (2)$$

Отличие используемых обучающих алгоритмов заключается в стратегии оптимизации и критерием ошибок. В обучающих алгоритмах в качестве меры ошибки используют среднеквадратичную ошибку E . Она определяется как сумма квадратов между экспериментальным значением температур $-y_k^r$ и значением, полученным нейросетью $-y_k$, для каждого примера $X(n,m)$ [11].

$$E = \frac{1}{2} \sum_{k=1}^m (y_k^r - y_k)^2$$

где y_k^r – экспериментальные значения температур; y_k – значения, полученные на сети.

Ошибка k -го нейрона выходного слоя определяется как:

$$d_k = \frac{\partial E}{\partial y_k} = y_k^r - y_k \quad (3)$$

Из выражений (1), (2) выразим производные через легко вычисляемые величины. Определим взвешенную сумму, аргумент функции активации как:

$$S_k = \sum_{j=1}^h w_{jk} g_j + T_k \quad (4)$$

Из соотношения (1) $\frac{\partial E}{\partial w_{jk}}$ можно представить как:

$$\frac{\partial E}{\partial w_{jk}} = \frac{\partial E}{\partial y_k} \frac{\partial y_k}{\partial S_k} \frac{\partial S_k}{\partial w_{jk}} \quad (5)$$

Где $\frac{\partial E}{\partial y_k} = d_k = y_k^r - y_k$ – ошибка k -го нейрона;

$\frac{\partial y_k}{\partial S_k} = f(S_k)$ – производная функция активации;

$\frac{\partial S_k}{\partial w_{jk}} = g_j$ – значение j -го нейрона предыдущего слоя.

Получаем

$$\frac{\partial E}{\partial w_{jk}} = d_k f(S_k) g_j \quad (6)$$

Аналогично (5), с учетом того, что $\frac{\partial S_k}{\partial T_k} = 1$, получаем

$$\frac{\partial S_k}{\partial T_k} = \frac{\partial E}{\partial y_k} \frac{\partial y_k}{\partial S_k} \frac{\partial S_k}{\partial T_k} = d_k f(S_k)$$

Весовые и пороговые коэффициенты скрытого слоя подстраиваются по выражениям (1), (2), с учетом (6).

Расчёт ошибки в явном виде, на основании выражения (3), не возможен.

Расчет осуществим через ошибки нейронов выходного слоя. Из этого вытекает название – алгоритм обратного распространения ошибки:

$$e_j = \frac{\partial E}{\partial g_j} = \sum_{k=1}^m \frac{\partial E}{\partial y_k} \frac{\partial y_k}{\partial S_k} \frac{\partial S_k}{\partial g_j} = \sum_{k=1}^m d_k f(S_k) w_{jk}$$

В результате работы программы выдается значение ошибки (рис.2). Анализ результатов обработки средней ошибки обучения, образца № 1 СКЛ, показал уменьшение среднего значения ошибки на 72%, до уровня 0,4.

Для корректировки и минимизации среднеквадратичной ошибки необходимо произвести подбор значений в матрице весовых значений, которая представляет из себя значения весов между входными нейронами и скрытым слоем нейронов. Количество строк определяет число входных переменных, а количество столбцов определяет число нейронов в скрытом слое.

$$E\delta = \begin{bmatrix} 0.93 & 0.87 & -0.42 & -0.07 & -0.36 & -0.34 & 0.69 & 0.34 & 0.55 & 0.17 \\ 0.29 & 0.49 & -0.26 & -0.25 & 0.68 & -0.82 & -0.96 & 0.89 & 0.01 & 0.69 \\ 0.85 & -0.25 & -0.87 & 0.31 & -0.06 & 0.44 & -0.43 & 0.55 & -0.88 & 0.54 \end{bmatrix}$$

Из размерности матрицы видно, что ИНС имеет три входных параметра и десять нейронов в скрытом слое. Корректировка происходит путем минимизации среднего значения квадрата ошибки E_δ , достигаемой в процессе итерационного обучения соответствуя алгоритму обратного распространения ошибки в соответствии с формулой (4):

$$\xi_{\delta+1} = \xi_\delta - \mu \left(\frac{\partial E_\delta}{\partial \xi_\delta} \right) + \nu (\xi_\delta + \xi_{\delta-1})$$

Где μ , ν – параметры алгоритма, по которым определяется темп и насколько устойчиво будет проходить обучение сети. Величина Градиента – $\frac{\partial E_{\delta}}{\partial \xi_{\delta}}$ в процессе вычисления глобального минимума в «долине» ошибки E_{δ} дает возможность определить вектор минимизации (по методике градиентного спуска) чтобы достигнуть глобального минимума, в результате чего получим новые значения матрицы весов $\xi_{\delta+1}$. График ошибки прогнозируемой температуры жилы представлен на рисунке 2.

Обучение происходит следующим образом. Вначале, формируем базу данных - задачник, сформированный в виде электронной Excel таблицы, содержащей (величины тока жилы СКЛ ($I_{ж}$), температуры внешней изоляции $\theta_{з.о}$ и температуры окружающей среды $\theta_{о.с}$). Затем, в автоматическом режиме эти данные подаются на вход НС, получаем от нее значение температуры – y_k . Вычисляя разность между значением температуры полученной от НС, и экспериментальным значением температуры – y_k^r , получаем вектор ошибки.

Сравнительный анализ точности обучения при различных алгоритмах обучения проведен в таблице № 2.

Таблица № 2

Результаты сравнения алгоритмов обучения

Алгоритм обучения нейронной сети	Средняя ошибка прогноза при 80% выборки	
	ε , °С	ε , %
Ливенберга-Марквардта	0,87	2,2
Байесова регуляризация	1,6	4,21
Градиентного спуска	2,13	5,6

Таким образом, исследования показали, что алгоритм Ливенберга-Марквардта имеет самую высокую точность, который и был выбран для решения задачи прогнозирования ресурса СКЛ.

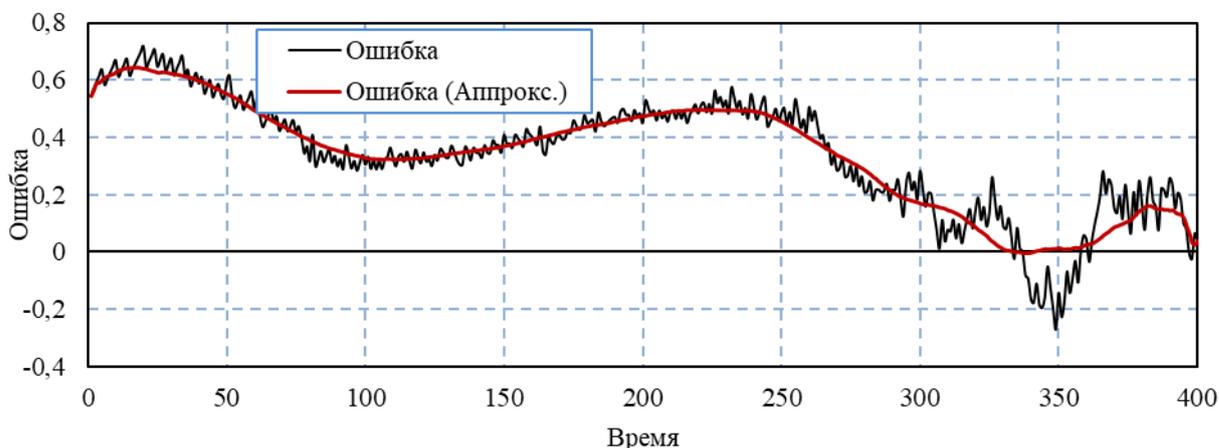


Рис. 2. - График ошибки прогнозируемой температуры жилы

Реализация нейросетевых моделей

При прогнозировании температуры жилы кабеля создание, обучение и моделирование нейронной сети осуществлялось с помощью Neural Network Toolbox в системе Matlab. Исследованы термофлуктуационные процессы в силовом кабеле (без повреждений) АПвПу г-1х240/25-10 при различных действующих значениях тока жилы кабеля, и разработанной модели прогноза с использованием ИНС на глубоких [10] ретроспективных данных температур исследуемого кабеля за 2015-2019 годы. Экспериментальные значения температур $\theta_{з.о}$, $\theta_{о.с}$ – защитной оболочки и окружающей среды, соответственно (рис.1), сняты с исследуемых образцов кабелей. Через образец кабеля пропускался ток, и фиксировалась температура $\theta_{з.о}$, $\theta_{о.с}$. На (рис. 3) приведены результаты прогноза температуры жилы кабеля ($\theta_{жс}$), для двух исследуемых образцов. Графики экспериментально снятой температуры и построенные нейросетью, на основе данных обучающей выборки, практически совпадают (рис.3).

Анализ результатов показал, что средняя ошибка прогноза температуры жилы кабеля $\theta_{ж}$ не превышает 2.5 %, что говорит о эффективности применения метода искусственных нейронных сетей в целях прогноза температуры токоведущей жилы кабеля по температуре на поверхности $\theta_{с.о}$ (рис.1, а).

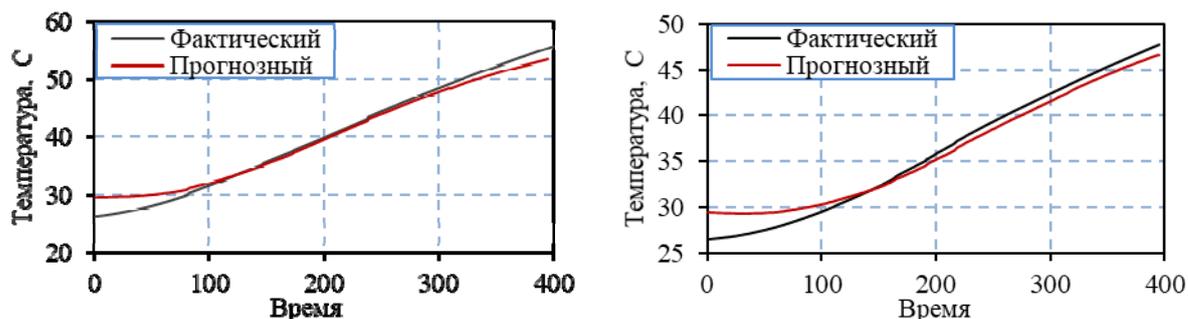


Рис. 3 – График фактической температуры кабеля и график построенный нейросетью, для двух образцов КЛ.

Выводы

Для определения температурных режимов токоведущей жилы силового кабеля разработана многослойная НС. Анализ полученных данных показал, что максимальная ошибка составила менее 2,5%, что является вполне приемлемым результатом. Получены функции для оценки длительно допустимых значений нагрева жилы кабеля напряжением 6-10 кВ с изоляцией из сшитого полиэтилена для различных значений тока жилы кабеля. Таким образом, можно прогнозировать пропускную способность линий.

Работа выполнена при поддержке внутреннего гранта ЮФУ «Разработка теоретических основ и интеллектуальных методов управления терминальным состоянием подвижных объектов в условиях неопределенности» № ВнГр 07/2017-19.

Литература

1. Поляков Д.А. Математическая модель расчета остаточного ресурса сшитой полиэтиленовой изоляции кабелей // ОНВ. 2017. №4 (154). URL: cyberleninka.ru/article/n/matematicheskaya-model-rascheta-ostatochnogo-resursa-sshitoy-polietilenovoy-izolyatsii-kabeley.

2. Бирюлин В.И., Куделина Д.В. Использование гибридных сетей для получения трендов процессов в изоляции кабельных линий // Auditorium. 2018. №4 (20). URL: cyberleninka.ru/article/n/ispolzovanie-gibridnyh-setey-dlya-polucheniya-trendov-protseessov-v-izolyatsii-kabelnyh-linij.

3. Poluyanovich N.K. Dubyago M.N. Study of characteristics of partial discharge for assessment of condition of electrical insulating materials of power supply system. // 2013 4th International Conference on Applied Mechanics and Mechanical Engineering (ICAMME 2013), October 11-12, 2013, Singapore, Applied Mechanics and Materials Vols. 459 Trans Tech Publications, Switzerland (2014) pp. 70-75.

4. . Shimada, A. Degradation distribution in insulation materials of cables by accelerated thermal and radiation ageing // IEEE Trans. Dielectr. Electr. Insul. - 2013. - Т. 20. - № 6. - С. 2107–2116.

5. Luo, P. Thermal and mechanical properties analysis for EHV XLPE cables with different operating years / P. Luo и др. // 2013 Annual Report Conference on Electrical Insulation and Dielectric Phenomena. - Т.3. - С.47–51.

6. Dubyago M.N., Poluyanovich N. K. Thermal processes of the isolating materials in problems of nondestructive diagnostics of the main and distributive power stations. // EAI Endorsed Transactions on Energy Web and Information Technologies 18(16): e3. ж. SJR SCImago Journal & Coutry Rank.

7. Карпушенко В. П., Золотарев В. В., Чопов Е. Ю., Бузько С. В. Электрическая система испытаний силовых кабелей всех классов напряжений с изоляцией из сшитого полиэтилена // ЕіЕ. 2013. №4. URL:

cyberleninka.ru/article/n/elektricheskaya-sistema-ispytaniy-silovyh-kabeley-vseh-
klassov-napryazheniy-s-izolyatsiey-iz-sshitogo-polietilena.

8. Сидоров С. Г., Вихарев А. В., и др. Многопроцессорная реализация нейросетевого алгоритма прогнозирования изменения характеристик электрической изоляции. // Вестник ИГЭУ, вып.1. 2011. URL: vestnik.ispu.ru/sites/vestnik.ispu.ru/files/publications/99-101.pdf.

9. Горева Т.И., Портнягин Н.Н., Пюкке Г.А., Нейросетевые модели диагностики технических систем // Вест. КРАУНЦ. Физ.-мат. науки. 2012. №1. URL: cyberleninka.ru/article/n/neyrosetevye-modeli-dagnostiki-tehnicheskikh-sistem.

10. Галушка В.В., Фахти В.А. Формирование обучающей выборки при использовании искусственных нейронных сетей в задачах поиска ошибок баз данных // Инженерный вестник Дона, 2013, №2. URL: ivdon.ru/ru/magazine/archive/n2y2013/1597/.

11. Пучков Е. В. Сравнительный анализ алгоритмов обучения искусственной нейронной сети // Инженерный вестник Дона 2013, №4. URL: ivdon.ru/ru/magazine/archive/n4y2013/2135.

References

1. Polyakov D.A., ONV. 2017. №4 (154). URL: cyberleninka.ru/article/n/matematiceskaya-model-rascheta-ostatochnogo-resursa-sshitoy-polietilenovoy-izolyatsii-kabeley.

2. Biryulin V.I., Kudelina D.V., Auditorium. 2018. №4 (20). URL: cyberleninka.ru/article/n/ispolzovanie-gibridnyh-setey-dlya-polucheniya-trendov-protse-ssov-v-izolyatsii-kabelnyh-liniy.

3. Poluyanovich N.K. Dubyago M.N., 2013 4th International Conference on Applied Mechanics and Mechanical Engineering (ICAMME 2013), October 11-12,



2013, Singapore, Applied Mechanics and Materials Vols. 459 Trans Tech Publications, Switzerland (2014) pp. 70-75.

4. Shimada, A. IEEE Trans. Dielectr. Electr. Insul. - 2013. - Т. 20. - № 6. - С. 2107–2116.

5. Luo, P. Thermal and mechanical properties analysis for EHV XLPE cables with different operating years / P. Luo и др. // 2013 Annual Report Conference on Electrical Insulation and Dielectric Phenomena. - Т.3. - С.47–51.

6. Dubyago M. N., Poluyanovich N. K., EAI Endorsed Transitions on Energy Web and Information Technologies 18 (16): e3. g. SJR SCImago Journal & Country Rank.

7. Karpushenko V.P., Zolotarev V.V., Chopov E. Yu., Buzko S.V., EiE. 2013. №4. URL: cyberleninka.ru/article/n/elektricheskaya-sistema-ispytaniy-silovyh-kabeley-vseh-klassov-napryazheniy-s-izolyatsiy-iz-sshitogo-polietilena.

8. Sidorov S. G., Vikharev A.V. et al. Vestnik IGEU, 2011, issue 1 URL: vestnik.ispu.ru/sites/vestnik.ispu.ru/files/publications/99-101.pdf.

9. T.I. Goreva, N.N. Portnyagin, G.A. Pücke, Vest. KRAUNTs. Fiz.-mat. nauki. 2012. No1. URL: cyberleninka.ru/article/n/neyrosetevye-modeli-dagnostiki-tehnicheskikh-sistem.

10. Galushka V.V., Fathi V.A. Inzhenernyj vestnik Dona, 2013, № 2. URL: ivdon.ru/ru/magazine/archive/n2y2013/1597/.

11. Puchkov E.V., Inzhenernyj vestnik Dona, 2013. № 4. URL: ivdon.ru/ru/magazine/archive/n4y2013/2135.