

Разработка интеллектуального комплекса для параллельной работы паровых котлов

E A Muravyova¹ and R F Gabitov

Ufa State Petroleum Technological University, Branch in Sterlitamak,
Sterlitamak, Russia

E-mail: muraveva_ea@mail.ru

Аннотация. Высокие темпы промышленного и социального прогресса требуют резкого увеличения выработки тепла на основе мощного развития топливно-энергетического комплекса. Проектирование параллельной работы нескольких котлов сегодня является важной и необходимой частью эффективной работы на рабочем месте. Параллельное подключение котла производится для: увеличения максимальной мощности и ее последующего увеличения, повышения отказоустойчивости котлов, экономичного энергопотребления за счет меньшей потери КПД при работе на частичной мощности, повышения жизненного ресурса котлов, экономичного энергопотребления за счет меньшей потери КПД при работе на частичной мощности, повышения котлы с живым ресурсом предотвращают локальный перегрев и закоксовывание труб при отделении тяжелых остатков. Несмотря на значительные преимущества использования параллельного подключения котла, существуют такие проблемы, как сложная система трубопроводов котла, расход материалов для подключения котла, увеличение непредвиденных расходов. При эксплуатации котлоагрегата в нем могут быть повреждены (трубопроводы, элементы котла, аварии водяных экономайзеров), стать нестабильными (пропуск воды из-за плохой вентиляции отсека, выбросы выхлопных газов, происходят взрывы и хлопки), что создает опасные ситуации, чреватые выходом из строя оборудования или котлоагрегата в целом, с разрушением и большими материальными потерями и гибелью людей. Нейронная сеть - это система контактов между простым процессором, работа которого заключается в обработке принятых сигналов и отправке их другим процессорам. Этот процессор называется нейроном. Искусственные нейронные сети выбраны для разработки систем управления технологическими процессами из-за того, что они являются отказоустойчивыми. В нейронной сети информация распределяется по всей сети, а это значит, что в случае сбоя нейронной сети поведение сети будет незначительно изменено, изменяя поведение нейронов, но сама сеть продолжает успешно функционировать. Нейронные сети не программируются в обычном смысле этого слова, они обучаются. Возможность обучения - одно из главных преимуществ нейронных сетей перед обычными алгоритмами. Техническая подготовка заключается в нахождении коэффициентов связей между нейронами. Во время обучения нейронная сеть способна идентифицировать сложные взаимосвязи между входными и выходными данными и выполнять синтез. Это означает, что в случае успешного обучения сеть сможет вернуть правильный результат на основе данных, которые не были доступны в обучающем наборе.

1. Вступление

Стабильная работа паровых котлов в параллельном режиме на электростанции (рис. 1) обеспечивается точным определением температуры в каждом котле, количества топлива, подаваемого в каждый котел, и давления в общем паропроводе, идущем далее в цех нагрева сырья. Количество подаваемого топлива фиксируется с помощью FLONET FN10 с FE 1a и FE 2a. Температура ниже по потоку от котлов - датчики температуры: термометр сопротивления ТС-1388 с позициями TE1a и TE 2a. Общее давление в паропроводе - датчик давления в положение 1 а. Из-за изменения степени открытия клапана количество подаваемого топлива соответственно изменяется.

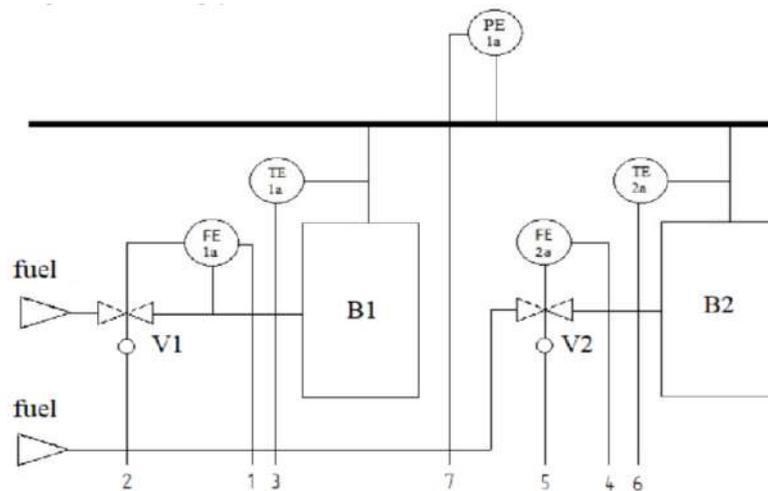


Рисунок 1. Схема параллельной работы котлов.

Таким образом, регулирование давления пара в общем паропроводе при параллельной работе котлов должно обеспечивать одновременное регулирование нагрузки нескольких котлов и позволять изменять участие каждого из них в покрытии общей электрической нагрузки станции.

Для стабилизации режима отдельных котлов не только при внешних, но и при внутренних возмущениях используется система управления с использованием нейронной сети.

В случае внутренних нарушений, например, когда подача топлива в один из котлов уменьшается, нейронная сеть увеличит подачу топлива в котел с низким количеством подаваемого топлива и снова восстановит его нагрузку до заданного значения.

Возможными проблемами управления параллельной работой паровых котлов являются следующие: снижение экономии, колебания выработки пара, снижение давления до вакуума. Поэтому использование нейронной сети для решения заданной задачи, а не стандартного ПИД-регулятора, позволит повысить качество решения и управления проблемой, а также нейронная сеть обладает высокой отказоустойчивостью и быстродействием [1, 2, 3].

2. Разработка нейронной сети

Необходимо разработать искусственную нейронную сеть (ANN) для управления котлами при параллельной работе на общей паровой магистрали.

Разработка INS проводилась в среде Matlab R2015b. Для решения этой задачи был использован инструментарий нейронных сетей Matlab [4].

Процесс построения нейросетевой модели можно условно разделить на 5 основных этапов.

Первым шагом в построении модели нейронной сети является тщательный отбор входных данных, влияющих на ожидаемый результат. Вся информация, относящаяся к исследуемой проблеме, должна быть включена из исходной информации.

На втором этапе исходные данные преобразуются с учетом характера и типа проблемы, отображаемой her-сетевой моделью, и выбираются методы представления формирования.

Третий шаг - спроектировать ANN, то есть спроектировать его архитектуру (количество слоев и количество нейронов в каждом слое).

Четвертый этап включает в себя сетевое обучение, которое может проводиться конструктивным или деструктивным образом. Согласно первому подходу, обучение INS проводится на небольшой сети, которое постепенно проводится до тех пор, пока не будет достигнута требуемая точность по результатам тестирования.

На пятом этапе полученная модель INS тестируется на независимой выборке примеров [5, 6].

2.1. Сбор данных

Чтобы решить задачу с помощью нейронной сети, необходимо собрать данные для ее обучения. Обучающий набор данных - это набор наблюдений, для которых заданы значения входных и выходных переменных.

Для создания обучающего набора для разрабатываемой нейронной сети мы будем использовать данные и формулу, полученные экспериментальным путем:

$$F = 100 - T_{1,2} \cdot (P_{\text{общ}})^{-1} \cdot Q_{1,2} \cdot 0.1 \quad (1)$$

Где F - степень открытия клапана 1 и клапана 2;

$T_{1,2}$ - температура в котле 1 или 2 соответственно;

$P_{\text{общ}}$, - давление в общем паропроводе;

$Q_{1,2}$ - количество топлива, подаваемого в котел 1 или 2 соответственно.

Далее мы подготовим данные для обучения нейронной сети.

2.2. Обработка и подготовка данных

Используя формулу (1), создайте таблицу 1 с обучающим набором данных. Он будет состоять из 1000 примеров.

На вход нейронной сети будет подано 5 значений:

2, Температура пара после котла 1, °C-TE1 а;

3, Температура пара после котла 2, °C-TE2 а;

4, Давление пара на общей паровой магистрали, кгс/см² - PE 1а;

5, Количество подаваемого топлива для нагрева воды в котле 1, т/ч-FE 1а;

6, Количество подаваемого топлива для нагрева воды в котле 2, т/ч -FE2а.

На выходе нейронная сеть должна вычислить:

1. Степень открытия клапана для подачи топлива в котел 1, %;

2. Степень открытия клапана для подачи топлива в котел 2, %.

2.3. Выбор типа и архитектуры нейронной сети

Необходимо разработать нейронную сеть для управления параллельной работой нескольких паровых котлов.

Для определения архитектуры нейронной сети была проанализирована возможность использования различных типов сетей в разных классах задач.

Структура нейронной сети выбирается в соответствии с особенностями и сложностью задачи. На самом деле количество слоев и количество нейронов в каждом слое нейронной сети ограничено ресурсами компьютера, на котором реализована разрабатываемая нейронная сеть, которая будет состоять из двух слоев - скрытого и выходного.

На первом этапе построения нейронной сети генерируются наборы обучающих выборок.

На втором этапе входные данные нормализуются, то есть определяется, попадает ли измеренное физическое значение в допустимые пределы датчика.

Третий этап - это выбор структуры нейронной сети. Будет использоваться двухслойная однонаправленная сеть с сигмоидальной функцией активации нейронов скрытого слоя и функцией активации нейронов линейного выходного слоя (созданной функцией fitnet). Такая сеть позволяет максимально точно решать задачи многомерной аппроксимации при условии согласованности данных и достаточного количества нейронов в скрытом слое ($\text{net} = \text{fitnet}(\text{hiddenLayerSize}, \text{trainFcn})$) [7].

На четвертом этапе нейронная сеть обучается на основе набора данных. Для построения и обучения нейронных сетей использовался нейронный инструментальный пакет Matlab [8].

На вход нейронной сети поступают значения температуры от датчиков температуры, количества подаваемого топлива от расходомеров и давления от датчика давления. В зависимости от каждого из входных значений нейронная сеть готовит на

выходе два значения, которые, в свою очередь, подаются на клапанные блоки, так что степень открытия каждого из них изменяется [9, 10, 11].

Сеть будет обучена с использованием модифицированного алгоритма обратного распространения ошибок $\text{trainFcn} = \text{'trainbr'}$. TrainBR - это функция обучения сети, которая изменяет веса и смещения в соответствии с алгоритмом оптимизации Левенберга-Маркварта. Это сводит к минимуму комбинацию квадратов ошибок и весов, а затем определяет исправленную комбинацию, что повышает способность сети к обобщению.

Затем мы выбираем параметры обучения сети.

Таблица 1. Входные переменные.

ВХОД					ВЫХОД	
$T_1, ^\circ\text{C}$	$T_2, ^\circ\text{C}$	$P_{\text{gen}}, \text{Kgf/sm}^2$	Q котел1, t/h	Q котел 2, t/h	% котел 1	% котел 2
791	4	30	29	29	22	56
453	5	29	27	26	58	52
532	5	29	25	30	54	45
769	8	27	29	32	19	4
338	3	30	29	27	68	69
306	8	26	30	26	64	18
379	3	31	30	30	63	70
431	4	29	27	31	60	56
608	5	32	29	29	45	51
383	5	31	28	28	65	47
792	4	30	28	27	26	63
553	6	31	30	30	46	39
551	3	26	31	31	35	63
679	6	27	31	28	20	36
596	8	26	28	32	36	1
372	5	31	25	32	70	41
625	2	30	25	31	48	73
670	6	25	30	32	20	18
604	6	25	26	26	37	34
564	4	31	29	28	47	57
278	3	25	31	27	66	62
697	7	27	32	28	17	19

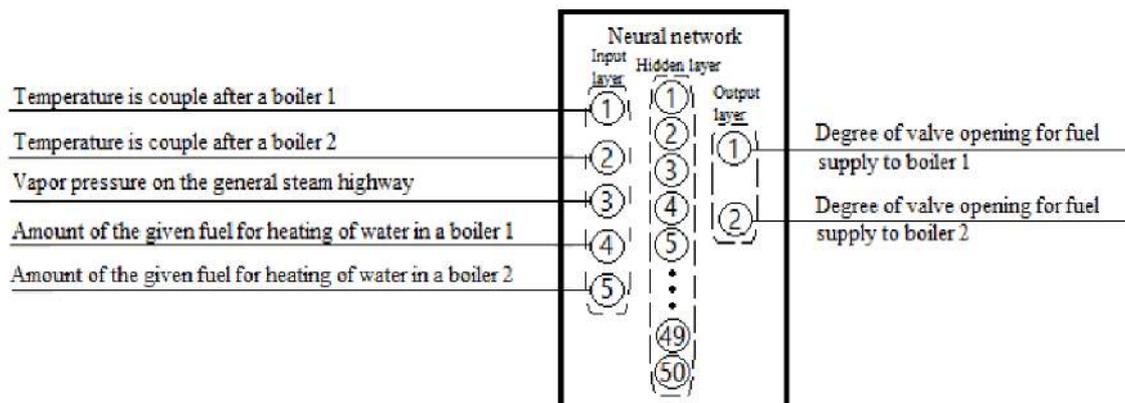


Рисунок 2. Структурная схема ANN.

Мы устанавливаем максимальное количество эпох обучения, которое определяет количество эпох (временной интервал), после которого обучение будет прекращено: $\text{net.trainParam.epochs} = 1000$.

Мы выберем количество эпох между показами равным пяти: `net.trainParam.show = 5`.

Мы указываем критерий завершения - значение отклонения, при котором обучение будет считаться завершённым:

```
net.trainParam.goal = 0.0001.
```

Далее мы разделяем данные на Обучающий набор, набор проверки, который используется для оценки обобщающих свойств сети и остановки обучения, когда обобщение перестает улучшаться, и Тестовый набор, который не влияет на обучение, но служит для тестирования на данных, которые не использовались при обучении сети:

```
net.divideParam.trainRatio = 60/100;
```

```
net.divideParam.valRatio = 35/100;
```

```
net.divideParam.testRatio = 5/100.
```

3. Построение и обучение нейронной сети в Matlab

Далее мы реализуем и обучаем нейронную сеть в Matlab. Для этого введите команду `uiopen`. Входные данные нейронной сети называются входными, а выходные данные - выходными. Загруженные данные отображаются в «Рабочей области» [11, 13, 14].

Входные данные - базовые - вводятся в виде матрицы с количеством строк - 48 и столбцов - 5, по которой будут выбраны выходные данные. Другой массив данных, который будет выводиться нейронной сетью, состоит из 48 строк и 2 столбцов.

Используя команду `nnstart`, вы войдете на вкладку Обучения нейронной сети, где вы реализуете задачу аппроксимации и регрессии. На этом этапе выбираются входные данные сети и выходные данные сети. Поскольку матрицы указаны в столбцах, в разделе «Образцы» мы выбираем «Строки матрицы».

Затем выбирается количество скрытых слоев нейронов - 50. В результате нейронная сеть будет представлена четырьмя блоками: вход, скрытый слой нейронов, выходной слой нейронов, выход (рис. 3). Блок «ввода» реализует процесс считывания входных данных, в нашем случае это температура пара после котлов №1 и №1, давление в общем паропроводе и расход топлива, подаваемого на каждый котел, и передает их на скрытый слой разработанной нейронной сети. Сумматор "умножает каждый входной сигнал b_i на вес w_i и суммирует взвешенные входные данные. Затем значение проходит через функцию активации соответствующего слоя и вычисляется результат: регулирование степени открытия клапана перед котлами № 1 и № 2.

Эта структура позволяет отслеживать ход обучения, а также вычислять статические результаты и отображать оценки качества обучения [12, 15, 16].

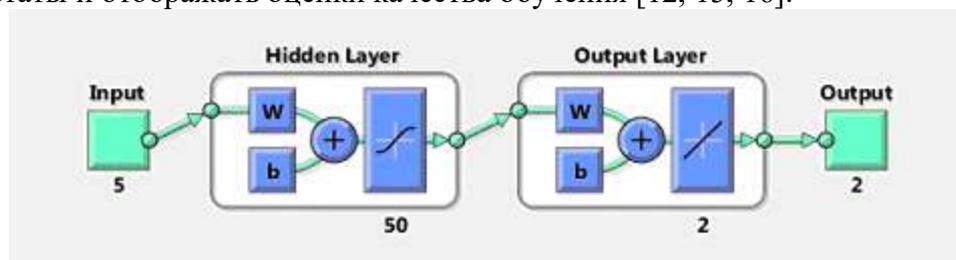


Рисунок 3. Блочная структура Нейронной Сети.

Следующим этапом формирования нейронной сети является выбор алгоритма, разработанного В. В этой работе был выбран алгоритм "байесовского регулирования", так как он работает более точно, чем другие.

Обучение нейронной сети длится в зависимости от количества указанных скрытых слоев, соответственно, чем больше слоев, тем больше времени займет обучение. Во время обучения выполняются итерации, то есть количество проходов, каждый из которых проходит заданный алгоритм - прямой и обратный проходы. Эпоха, в свою очередь, является количеством раз, когда алгоритм считывает весь набор данных, матрицу. Таким

образом, каждый раз, когда алгоритм подсчитывает все выборки в наборе данных, эпоха завершается [8, 9, 11].

В окне процесс обучения сети, нажав на кнопку Производительность, вы можете увидеть расписание обучения сети, показывающее поведение ошибок обучения, показанное на рисунке 4.

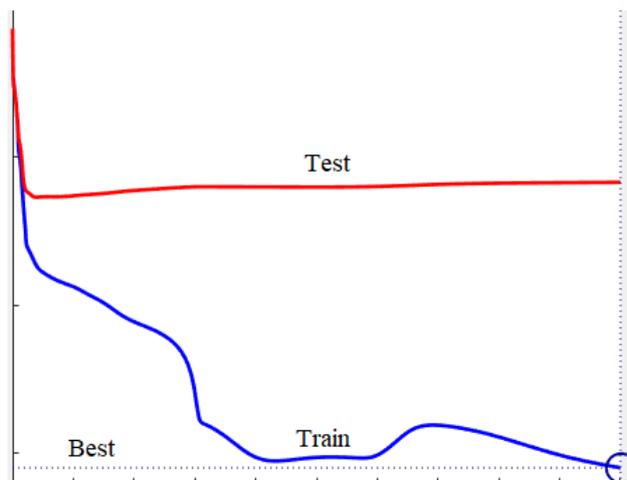


Рисунок 4. Средняя квадратичная ошибка.

Для 1000 вычеркните значение среднеквадратичной ошибки $3,2371 \cdot 10^{-11}$ достигается. Это означает, что значения исследуемой величины лежат в непосредственной близости друг от друга, а значит, погрешность значений будет минимальной. Функция обучения использует раннее прекращение обучения в качестве средства предотвращения переобучения. MSE - это функция производительности сети. Он показывает производительность в соответствии со средней квадратичной ошибкой [10, 12].

На рисунке 5 показаны графики состояния обучения. График "val fail" показывает изменение ошибки в наборе элементов управления. Параметр val fail показывает количество итераций, в которых ошибка была меньше указанной. Таких итераций не было, что указывало на точную работу нейронной сети.

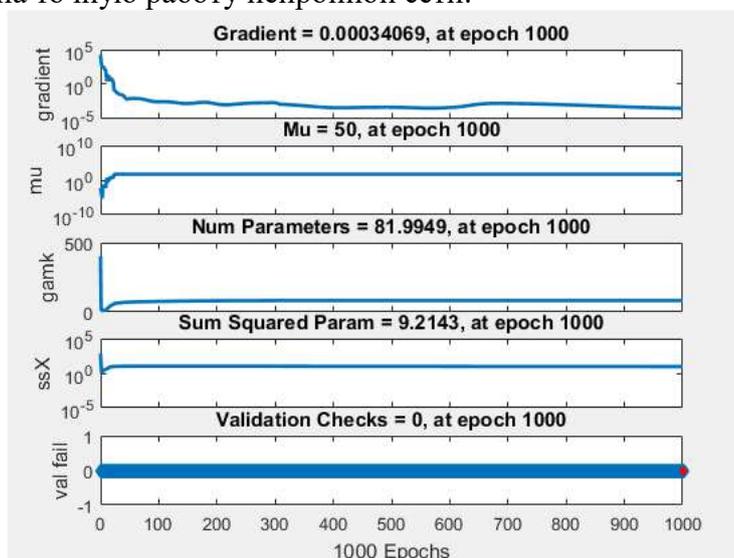


Рисунок 5. Графики сетевого обучения.

График "ssX" показывает среднюю сумму квадратичных параметров за 1000 эпох, которые вносят ошибки в конечный результат работы нейронной сети. Значение функции "ssX" равно 9,2143, что обусловлено минимальным влиянием ошибок на общий результат обучения нейронной сети.

График "gamk" показывает среднее количество параметров на 1000 эпох, которые повлияли на точность достигнутого результата. Значение функции "gamk" принимает

значение 81.9949, что показывает, что влияние внешних факторов, таких как ошибки, происходило часто.

График "mu" отражает изменение параметра обучения [pi] байесовского метода регуляризации, и чем выше заданное значение [pi], тем точнее будет обучение сети. Значение "mu", равное 50, означает, что математическое ожидание достигло верхнего допустимого предела в 1000 эпох.

График "градиента" показывает изменение градиента функции по весам сети на каждой итерации. На каждой последующей итерации ошибка приближается к нулю. Значение $grade = 0.00034069$ означает, что ошибка практически минимальна.

В результате обучения получается нейронная сеть, которая без перенастройки весов связей генерирует выходные сигналы при подаче на вход сети любого набора входных сигналов из обучающего набора [8, 9].

4. Проверка нейронной сети

Чтобы протестировать нейронную сеть, используйте команду `sim (net, [x1; x2; x3; x4; x5])` для ввода 5 значений. Контрольные входные данные, показанные в таблице 2, выбираются случайным образом в соответствии с правилами и верхними/нижними границами измерения. На их основе нейронная сеть вычисляет выходные данные ANN [15].

С помощью текстовых команд проверяется правильность подготовки ANN для управления параллельной работой паровых котлов. В результате тестирования истинность выходных значений равна (55.2311; 58.1423). Близость полученных значений к заданному результату (55; 58) указывает на применимость сети. Из этого следует, что параметры данных нейронной сети выбраны правильно [16].

Таблица 2. Данные проверки.

Вход				Выход		
Temperature is couple later copper 1, °C	Temperature is couple after a copper 2, °C	Steam pressure on the common steam line, kgf/cm ²	Amount of fuel supplied to boiler 1, t/h	Amount of fuel supplied to boiler 2, t/h	Extent of opening of the valve, %	Extent of opening of the valve, %
430	436	26	2	25	55.2311	58.1423

5. Заключение

В ходе решения задачи управления параллельной работой паровых котлов обоснована и показана целесообразность разработки системы автоматического управления на основе нейронной сети параметрами паровых котлов при их параллельной работе с учетом взаимного влияния параметров объекта.

Представлена модель управления системой парового котла с учетом взаимосвязей между параметрами процесса. При разработке нейронной сети выбирается наиболее оптимальное количество скрытых слоев, выбранный алгоритм обучения эффективен при заданной задаче и при заданных условиях и параметрах.

Стабильная работа и низкая среднеквадратичная погрешность обеспечивают высококачественное использование нейронной сети для управления котлами в режиме реального времени.

Рекомендации

1. Muravyova E and Popkov V 2019 Development and Research of a Dynamic Flow Laboratory Bench Model *7th Scientific Conference on Information Technologies for Intelligent Decision Making Support* (Ufa: (ITIDS)) pp 117-22
2. Yakhyayeva G 2006 *Fuzzy Sets and Neural Networks* (Moscow: Internet University of Information Technologies; Binom) p 316

3. Popov A, Sayarkin K and Zhylenkov A 2018 *The scalable spiking neural network automatic generation in MATLAB focused on the hardware implementation* (Moscow: IEEE) pp 285-287
4. Rashid T 2016 *Make Your Own Neural Network* (North Charleston: publisher: «CreateSpace») p.222
5. Muravyova E and Gabitov R 2018 Economic Features to Optimize the Catalyst Calcinations Process *International Scientific Multi-Conference on Industrial Engineering and Modern Technologies* (Vladivostok: IEEE) p. 178
6. Muravyova E, Sharipov M and Gabitov R 2018 SCADA-System Based on Multidimensional Precise Logic Controller for the Control of a Cement *International Scientific Multi-Conference on Industrial Engineering and Modern Technologies* (Vladivostok: IEEE) p. 260
7. Kriesel D 2014 *Brief Introduction to Neural Networks* (Peru: «Autoedicin») .p 244
8. Samarasinghe S 2016 *Neural Networks for Applied Sciences and Engineering* ([Boca Raton](#):«CRC Press») p. 570
9. Evmenov V 2009 *Intelligent Control Systems* (Moscow, Russia: book house "Librokom") p 290
10. Muravyova E and Almakaev I 2019 Electrical Heating Reactor Control System Using Neural Network and the Fuzzy Controller *International Multi-Conference on Industrial Engineering and Modern Technologies* (Vladivostok: (FarEastCon)) pp. 250-6
11. Muravyova E and Sharipov M 2018 Intelligent Control System for Process Parameters Based on a Neural Network *Actual problems of electronic instrument engineering* (Novosibirsk: APEIE) pp. 256-60
12. Haikin S 2006 *Neural Networks: a Complete Course* (Moscow: Publishing house «Williams») p. 1104
13. Barsky A 2004 *Neural Networks: Recognition, Management, Decision-Making* (Moscow, Russia: «Finance and statistics») p. 176
14. Andrzej Cichocki and Seungjin Choi 1998 *Cascade Neural Networks for Multichannel Blind Deconvolution* (Stevenage: Electronics Letters vol. 34) pp. 1186-7
15. Sherfey Jason S, Soplata Austin E, Ardid Salva, Roberts Erik A, Stanley David, Pittman-Polletta Benjamin R and Kopell Nancy J DynaSim 2018 *A Matlab Toolbox for Neural Modeling and Simulation* (Oslo: Published in Frontiers in Neuroinformatics) pp. 1183-92
16. Muravyova E and Sharipov M 2018 Method of Optimal Parameters Control in Three-Phase Separator using Fuzzy Controller *International Conference on Actual Issues of Mechanical Engineering* (Novosibirsk: AIR) pp 418-23.