

МЕТОД ОЦЕНКИ СОСТОЯНИЯ ЭЛЕМЕНТОВ ИНФОРМАЦИОННО-ТЕЛЕКОММУНИКАЦИОННЫХ СИСТЕМ С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ

Предложен метод оценки состояния элементов информационно-телекоммуникационных систем с использованием нейронных сетей. Приведена сравнительная характеристика результатов оценки состояния с помощью нейронных сетей различных типов. Разработан метод оценки состояния элементов с помощью машины опорных векторов.

The method of components state appraisal of Information and telecommunication systems' with neural networks application is proposed. The comparative description of the state appraisal results with neural networks of various types is given. The method of components state appraisal with the assistance of support vector machine is designed.

Введение

Бизнес рассматривает информационные технологии (ИТ) в качестве средства повышения своей производительности и улучшения конкурентоспособности. Эффективность и надежность предоставления ИТ-услуг бизнес-пользователям зависит от надежного и качественного функционирования информационно-телекоммуникационной системы (ИТС). ИТС, как совокупность информационной системы и телекоммуникационной сети, является информационно-инфраструктурной основой выполнения бизнеса. Для автоматизации управления ИТС и поддержки принятия решений администраторами информационно-коммуникационных технологий разрабатываются и внедряются системы управления ИТС (СУИ) [1]. Для эффективного управления ИТС необходимо, чтобы СУИ получала и обрабатывала информацию о состоянии всех составляющих ИТС. Поэтому данная статья, посвященная разработке метода оценки состояния элементов и подсистем ИТС с использованием нейронных сетей, является актуальной.

Постановка проблемы

Для поддержания значений параметров, характеризующих надежность и эффективность функционирования ИТС на заданном соответствующим регламентом уровне, администраторы должны максимально быстро обнаруживать и устранять неисправности в ИТС, а также своевременно осуществлять мероприятия по поддержанию параметров производительности ИТС на заданном уровне. Для автоматизации

выполнения этих функций в СУИ должна непрерывно поступать информация о состоянии элементов мониторинга и управления (ЭМУ), а также результаты анализа тенденций изменения этих состояний, необходимые для проактивного управления ИТС. Поскольку для оценки состояния ЭМУ необходимо выявлять связи и оценивать значения разных по типу быстроизменяющихся параметров, учитывать зависимости между состояниями элементов различных иерархических уровней ИТС, быстро адаптироваться к изменению структуры связей параметров и вкладу параметров в общую оценку состояния ЭМУ, целесообразным видится применение нейронных сетей при оценке состояния ЭМУ. Поэтому возникает необходимость определения типа нейронной сети, которая покажет наилучшие результаты при решении задач автоматической оценки состояния ЭМУ.

Анализ публикаций

В [1] предлагается метод кодирования состояний ЭМУ, а оценка работоспособности ЭМУ осуществляется с помощью тестовых проверок, когда для обнаружения неисправного элемента производится последовательность тестов, причем каждая последующая проверка выбирается с учетом результатов предыдущей проверки. Для успешной реализации этого метода необходимо иметь обширную базу знаний, кроме того, требуется значительное время для поиска неисправного ЭМУ.

В [2] предложено оценивать работу элементов и подсистем ИТС по интегральному показателю качества функционирования. В [3] предложен метод сведения метрик оценки качества

функционирования ЭМУ, позволяющий своевременно реагировать на изменение состояния ЭМУ. Достоинством этих подходов является их гибкость. Однако, при увеличении количества параметров значительно увеличивается объем вычислений.

В [4] рассмотрен агентский подход к анализу и оценке состояния ЭМУ. Сравняются два способа получения значений о параметрах, характеризующих состояние элементов: непосредственное обращение сервера СУИ и опрос элементов ИТС агентами с передачей обобщенных результатов серверу СУИ.

Целью данной работы является разработка метода оценки состояния элементов ИТС с использованием нейронных сетей и определения типа сети, наиболее подходящего для решения задач оценки состояния.

Суть предлагаемого метода оценки состояния элементов ИТС

Анализ известных подходов к определению состояния элементов ИТС [1–4] позволяет сделать вывод о том, что задачу оценки и прогнозирования состояния ЭМУ можно свести к задаче создания технологии, в которой математические модели элементов ИТС играют роль супервизоров для искусственных нейронных сетей (НС).

Для обучения НС формируют множество $R = \{S, W, Y\}$, где $S = \{s_n\}$ – множество значений параметров ЭМУ, $n = \overline{1, N}$, N – количество параметров ЭМУ, влияющих на его состояние; $W = \{w_n\}$, $n = \overline{1, N}$ – множество стартовых весовых коэффициентов НС; $Y = \{y_k\}$, $k = \overline{1, K}$, – множество контрольных состояний ЭМУ.

В процессе обучения НС на ее входы поступают входные сигналы, соответствующие элементам s_n , $n = \overline{1, N}$. Взвешенные весовыми коэффициентами соединения w_n , $n = \overline{1, N}$, входные сигналы суммируются, проходят через передаточную функцию, генерируют результат u , поступающий на выход НС, где он сравнивается с контрольным значением из множества Y . По результатам отклонения u от y_k , $k = \overline{1, K}$ формируется значение ошибки E , на минимизацию которой и направлено обучение НС с супервизором. Обучающая выборка должна быть сформирована таким образом, чтобы примеры

охватывали всю плоскость исследований, а ошибка E стремилась к минимуму в каждом эксперименте.

Первым и одним из наиболее сложных этапов разработки системы оценки состояния ЭМУ с использованием НС является формирование обучающей выборки. На этом этапе из накопленных данных о работе ЭМУ формируется обучающая выборка так, чтобы максимально полно и равномерно были представлены все возможные состояния ЭМУ. От качества обучающей выборки зависит качество обучения. На сегодняшний день отсутствуют эффективные формальные критерии оценки качества обучающей выборки, на основании которых возможна разработка методик, ориентированных на оптимизацию этой выборки. Отсутствуют формальные, обоснованные с точки зрения особенности задачи и средств ее решения, методики повышения качества обучающей выборки. Поэтому было принято решение использовать нормированные значения параметров ЭМУ в закодированном виде, оценка которых произведена администратором предварительно.

При формировании обучающей выборки необходимо определить критерии подбора значений параметров ЭМУ. В равной степени должно быть уделено внимание всем возможным состояниям ЭМУ, а также должна проследиваться зависимость состояния ЭМУ от значений параметров. Каждый ЭМУ имеет множество P_i параметров $p_{n,i}$, $n = \overline{1, N_i}$, $i = \overline{1, I}$, где N_i – количество параметров i -го ЭМУ, I – количество ЭМУ, оказывающих влияние на качество функционирования i -го ЭМУ. Множество P_i формируется на основании анализа функциональных и физических параметров, а также состояния других ЭМУ, влияющих на состояние оцениваемого i -го ЭМУ [2]. Значение каждого из параметров множества P_i , $i = \overline{1, I}$ нормируется и приводится к отрезку $[0, 1]$, причем ЭМУ, функционирующему в соответствии с заданным регламентом, соответствуют значения параметров, равные 1. После этого значение параметра кодируется и подается на вход НС.

Количество рабочих входов НС должно соответствовать количеству N_i параметров i -го ЭМУ, оценка состояния которого осуществля-

ется. Для этого при оценке состояния i -го ЭМУ активизируется количество входов НС, равное N_i .

Оценка состояния ЭМУ заканчивается появлением на выходе НС закодированного значения состояния \bar{Y} :

$$\bar{Y} = f(s_{n,i}, n = \overline{1, N}, i = \overline{1, I}),$$

где $s_{n,i}$, $n = \overline{1, N}, i = \overline{1, I}$ – значение параметра $p_{n,i}$.

Для кодирования состояния ЭМУ целесообразно использовать метод, предложенный в [1]. Суть кодирования заключается в следующем.

Для каждого i -го ЭМУ, $i = \overline{1, I}$ значения параметров $s_{n,i}$, $n = \overline{1, N}$ приводятся к численному виду, преобразовываются так, чтобы максимальному значению параметра $p_{n,i} - \max s_{n,i}$ соответствовал максимальный положительный вклад в определение состояния i -го ЭМУ, и нормируются относительно $\max s_{n,i}$. При этом значения $s_{n,i}$ будут лежать в отрезке $[0, 1]$, т. е. $0 \leq s_{n,i} \leq 1$, для всех $n = \overline{1, N}, i = \overline{1, I}$.

Интервал изменения $s_{n,i}$, $n = \overline{1, N}$ разбивается на $M_{n,i}$ непересекающихся диапазонов $d_{n,i}^{(m_n)}$, $m_n = \overline{1, M_{n,i}}$ с использованием $L_{n,i} = (M_{n,i} - 1)$ пороговых значений $P_{n,i}^{(l_n)}$, $l_n = \overline{1, L_{n,i}}$. Нумерация диапазонов начинается от значения $\max s_{n,i}$, равного 1.

Принадлежность значения $s_{n,i}$ к диапазону $d_{n,i}^{(m_n)}$, $s_{n,i} \Rightarrow d_{n,i}^{(m_n)}$, определяется следующим образом. Если выполняется условие:

$$\frac{1}{(L_{n,i} + 1)}(L_{n,i} + 1 - d_{n,i}^{(m_n)}) \leq s_{n,i} \leq \frac{1}{(L_{n,i} + 1)}(L_{n,i} + 2 - d_{n,i}^{(m_n)}),$$

состояние $s_{n,i}$ кодируется символом $A_{b_{m_n}}^{(M_{n,i})}$ так, что значение $b_{m_n}, m_n = \overline{1, M_{n,i}}$ соответствует номеру диапазона $d_{n,i}^{(m_n)}$, в котором находится значение $s_{n,i}$.

Символ $A_{b_{m_n}}^{(M_{n,i})}$ принадлежит алфавиту $A = \{A_{b_{m_n}}^{(M_{n,i})}, m_n = \overline{1, M_{n,i}}, n = \overline{1, N}\}$.

Кодовая комбинация для обозначения состояния S_i i -го ЭМУ, $i = \overline{1, I}$ будет выглядеть следующим образом:

$$A_{b_{m_1}}^{(M_{1,i})} A_{b_{m_2}}^{(M_{2,i})} \dots A_{b_{m_N}}^{(M_{N,i})}.$$

Пример кодирования состояния ЭМУ для случая пятипорогового ($L_{2,i} = 5$) ранжирования состояний приведен в табл. 1.

Кодовая комбинация для обозначения состояния S_i i -го ЭМУ, $i = \overline{1, I}$ будет выглядеть, например, следующим образом: $A_3^{(5)} A_4^{(5)} A_4^{(5)} A_3^{(5)} A_4^{(5)}$.

Комбинация поступает на входы обученной нейронной сети. На ее выходе состояние элемента характеризуется одним символом алфавита $A = \{A_{b_1}^{(M_{1,i})}, m_1 = \overline{1, M_{1,i}}\}$. Значения порогов устанавливаются администраторами и могут меняться в процессе работы. НС выдает код состояния, в котором находится ЭМУ в текущий момент времени. Схема метода поясняется рис. 1.

Табл. 1. Пример кодирования состояния ЭМУ при пятипороговом ранжировании

Код состояния i -го ЭМУ при $n=5$	Показатель производительности i -го элемента	Лингвистические переменные описания состояния элемента
$A_4^{(5)}$	$P_{3,i}^{(l_3)} \leq s_{1,i} \leq 1$	«Отлично»
$A_3^{(5)}$	$P_{2,i}^{(l_2)} \leq s_{1,i} \leq P_{3,i}^{(l_3)}$	«Хорошо»
$A_2^{(5)}$	$P_{1,i}^{(l_1)} \leq s_{1,i} \leq P_{2,i}^{(l_2)}$	«Удовлетворительно»
$A_1^{(5)}$	$P_{0,i}^{(l_0)} \leq s_{1,i} \leq P_{1,i}^{(l_1)}$	«Неудовлетворительно»
$A_0^{(5)}$	$0 \leq s_{1,i} \leq P_{0,i}^{(l_0)}$	«Критично»




Рис. 1. Схема метода оценки состояния элементов ИТС

Результаты исследований

Обучение НС заканчивается построением гиперплоскостей, разделяющих область возможных состояний ЭМУ на непересекающиеся зоны, каждая из которых соответствует отдельному состоянию, определяемому, например, по табл. 1. Для оценки состояния элементов ИТС использовались нейронные сети трех типов: сеть Хопфилда (СХ), радиально базисная нейронная сеть (РБС) и машина опорных векторов (МОВ). Для каждой НС проводилось обучение с супервизором, при этом учитывались индивидуальные особенностей работы НС [5–8].

В качестве примера для проверки предлагаемого метода оценки состояния элементов ИТС

с помощью нейронных сетей выбран ЭМУ типа «сервер», состояние которого оценивается по значениям таких параметров: 1) время ожидания доступа к носителям; 2) загрузка процессора/оперативной памяти; 3) свободная оперативная память: виртуальная память и память подкачки; 4) загруженность сетевых интерфейсов; 5) температура физических компонентов. По первым четырем параметрам оценивается текущая работоспособность сервера, а пятый позволяет выявить возможную причину неисправностей. Для первого исследования метода использовалась выборка по элементам ИТС типа «сервер» с параметрами 1)–4) (см. табл. 2), а для второго – с параметрами 1)–5) (см. табл. 3). Количество проводимых испытаний 100 и 1000.

Табл. 2. Количество ошибок, допущенных СХ, РБС и МОВ при четырех параметрах

Тип НС	Состояние, в котором находится ЭМУ тестовой выборки											
	$A_0^{(5)}$		$A_1^{(5)}$		$A_2^{(5)}$		$A_3^{(5)}$		$A_4^{(5)}$		Случайное	
	100	1000	100	1000	100	1000	100	1000	100	1000	100	1000
СХ	2	17	4	32	3	34	3	39	1	9	3	38
РБС	0	3	1	3	0	12	1	9	0	2	1	7
МОВ	0	0	0	2	1	2	0	2	0	0	0	2

Табл. 3. Количество ошибок, допущенных СХ, РБС и МОВ при пяти параметрах

Тип НС	Состояние, в котором находится ЭМУ тестовой выборки											
	$A_0^{(5)}$		$A_1^{(5)}$		$A_2^{(5)}$		$A_3^{(5)}$		$A_4^{(5)}$		Случайное	
	100	1000	100	1000	100	1000	100	1000	100	1000	100	1000
СХ	3	23	5	52	3	42	5	37	2	11	4	36
РБС	0	4	1	3	0	12	1	8	0	5	1	14
МОВ	0	1	0	4	1	3	0	4	0	0	0	3

Как видно из табл. 2 и 3, СХ показала худшие результаты распознавания состояния. При определении состояния ЭМУ, не являющемся предельным во множестве состояний: «критическое» – «плохое» – «удовлетворительное» –

«хорошее» – «отличное», погрешность доходит до 5%.

РБС показала результаты на порядок лучше СХ. Это обусловлено тем, что на выходе НС выполняется операция математического округ-

ления чисел до ближайшего целого. Максимальная погрешность до операции округления составляла 0,4. Постоянная погрешность в 85% случаев находилась в диапазоне до 0,1, что является хорошим результатом.

МОВ в данной задаче представляет собой линейный пороговый классификатор, обучающийся по прецедентам, который для множества P_i , $i = \overline{1, I}$ параметров i -го ЭМУ, принимающих значения из множества S_i значений парамет-

ров, и множества контрольных значений $Y = \{y_k\}$ строит алгоритм $\alpha_i : s_i \rightarrow y_k$, $i = \overline{1, I}$, аппроксимирующий целевую зависимость на всем пространстве изменения значений S_i , $i = \overline{1, I}$ [9]. Точность построения гиперплоскости зависит от объема и качества обучающей выборки. Вероятность погрешности не превышает 0,01–0,02%.




Рис. 2. Результаты тестирования CX, PBC и MOV при $n=5$ для: а) ЭМУ, находящихся в состоянии $A_0^{(5)}$; б) ЭМУ – в состоянии $A_1^{(5)}$; в) ЭМУ – в состоянии $A_2^{(5)}$; г) ЭМУ – в состоянии $A_3^{(5)}$; д) ЭМУ – в состоянии $A_4^{(5)}$

Из графиков (см. рис. 2) видно, что СХ допускает 2–5% ошибок при оценке состояния элементов ИТС, находящихся в приграничной области состояний.

Особенности работы РБС подразумевают написание подпрограммы, которая будет осуществлять операцию математического округления на выходе НС, поскольку в РБС выход является аналоговым. РБС допускает в среднем 1% ошибок.

Все допущенные нейронными сетями ошибки были связаны с недостаточной точностью построения разделяющей гиперплоскости. Как видно из результатов практических исследований, наиболее точно гиперплоскости определяются при помощи МОВ.

По показателям простоты и скорости обучения, быстродействия сети и точности результатов целесообразно использование машины опорных векторов в качестве основной аналитической составляющей подсистемы оценки состояния элементов ИТС.

При использовании МОВ для определения состояния ЭМУ решается задача определения принадлежности ЭМУ к одному из двух классов. В этом случае необходимо реализовать $M_{n,i}$ параллельных МОВ – линейных пороговых классификаторов, обучающихся по прецедентам. Каждая из параллельных МОВ строит собственную разделяющую гиперплоскость по уравнению $\langle W, S \rangle = W_0$, где

$W_0 = (w_{00}, w_{01}, \dots, w_{0m})$, $m = \overline{1, M_{n,i}}$ – скалярный порог между классами. Главной задачей обучения является построение оптимальной разделяющей гиперплоскости с максимизацией ее ширины.

МОВ соотносит объект с определенным классом по следующей схеме [9]:

$$Y_k = \text{sign}\left(\sum_{i=1}^N w_i s_i - w_0\right) = \text{sign}(\langle W, S \rangle - W_0).$$

Структура нейронной сети для оценки состояния ЭМУ с использованием МОВ приведена на рис. 3.

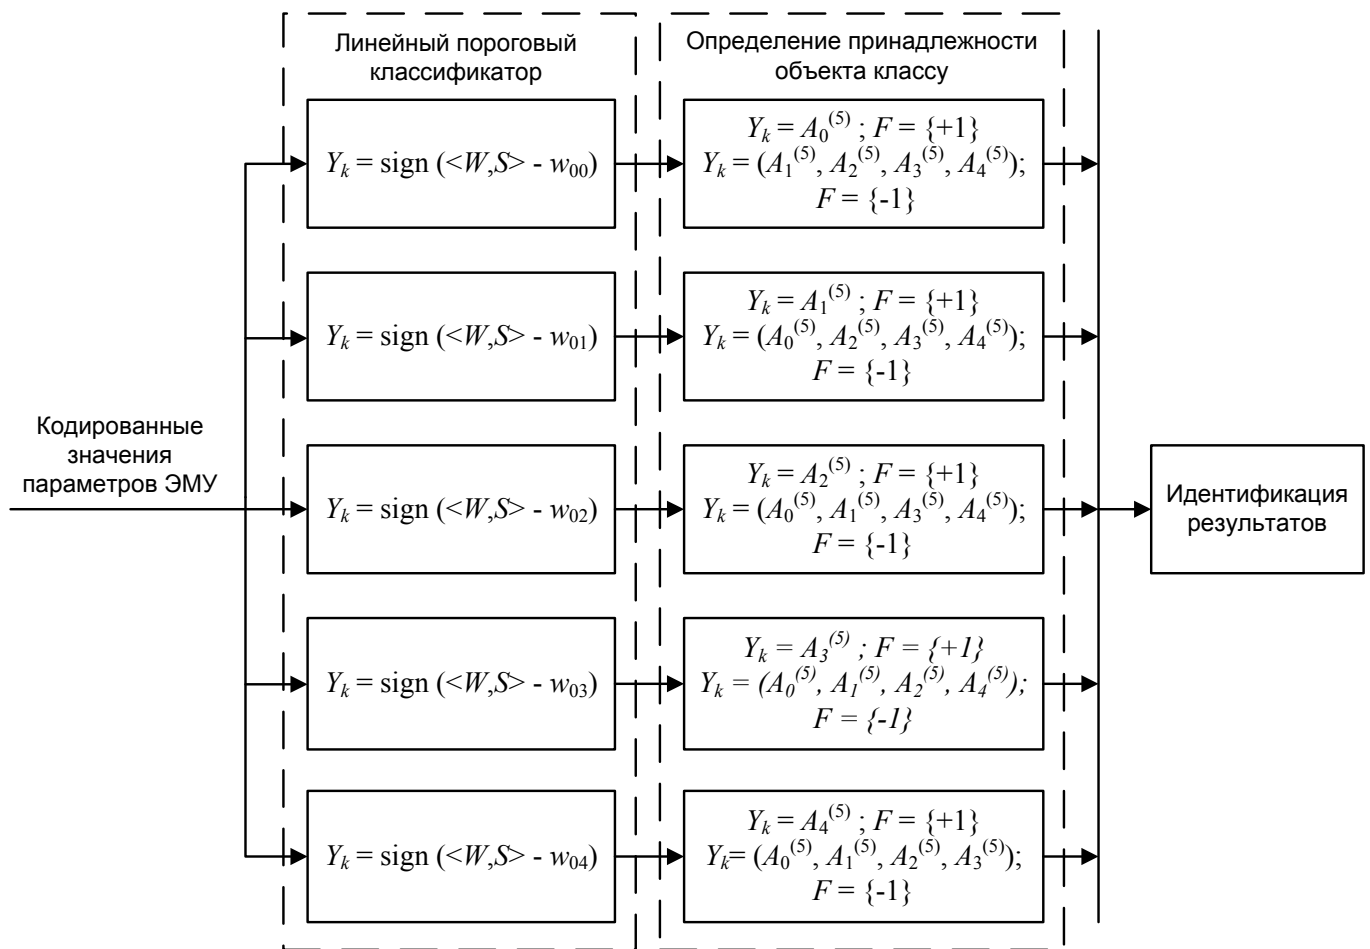


Рис. 3. Структура нейронной сети на основе машины опорных векторов

Нейронная сеть, построенная по методу опорных векторов и показавшая лучшие ре-

зультаты при экспериментальных исследованиях, является мощным и перспективным направ-

лением обработки данных при решении задачи классификации состояний элементов ИТС. Это позволяет рекомендовать ее для применения в системах управления ИТС.

Выводы. Предложено для оценки состояния элементов ИТС использовать аппарат нейронных сетей. Приведена система кодирования состояний элементов ИТС при формировании обучающей и тестовой выборки. Для решения задачи определения состояний ЭМУ ИТС протестированы сеть Хопфилда, радиально-

базисная нейронная сеть и нейронная сеть, построенная по методу опорных векторов. Приведена сравнительная характеристика результатов оценки состояния с помощью этих сетей. Разработан метод оценки состояния элементов ИТС с помощью машины опорных векторов. Алгоритм определения состояния элементов ИТС применен для оценки состояния элементов ИТС в СУИ SmartBase ITSControl, разрабатываемой в НТУУ «КПИ».

Список литературы

1. Теленик С.Ф. Методы диагностики компонентов информационно-телекоммуникационных систем/ С.Ф. Теленик, А.И. Ролик, Ю.С. Тимофеева // «Наукові вісті» Ін-ту менеджменту і економіки «Галицька академія». – Івано-Франківськ, 2009. – № 1 (15). – С. 49–58.
2. Ролик А.И., Глушко Е.В. Анализ качества функционирования элементов информационно-телекоммуникационных систем// Вісник НТУУ «КПІ». Інформатика, управління та обчислювальна техніка.– К.: – 2008. – № 48. – С. 113–120.
3. Ролік О.І. Метод зведення метрик якості функціонування компонентів ІТ-інфраструктури за допомогою апарату непараметричної статистики / О.І. Ролік, П.Ф. Можаровський, В.М. Вовк, Д.С. Захаров // Вісник НТУУ «КПІ»: Інформатика, управління та обчислювальна техніка. – К.: «ВЕК+», 2011. – № 53. – С. 160–169.
4. Ролік О.І. Застосування агентського підходу до управління інформаційно-телекомунікаційною системою АСУ спеціального призначення / О.І. Ролік, П.Ф. Можаровський, О.О. Покотило // Пріоритетні напрямки розвитку телекомунікаційних систем та мереж спеціального призначення: V наук.-практ. семінар, 22 жовт. 2009 р.: доповіді та тези доповідей: – К.: ВІПІ НТУУ «КПІ», 2009. – С. 228–229.
5. Boser В.Е. A training algorithm for optimal margin classifiers/ В.Е. Boser, І.М. Guyon, V.N. Vapnic // ACM. – 1992. – С. 1–7.
6. Круглов В.В. Искусственные нейронные сети. Теория и практика. 2-е изд. // В.В. Круглов, В.В. Борисов // ГЛ Телеком. – 2002. – С. 63–65.
7. Хайкин С. Нейронные сети. Полный курс. Второе издание // С. Хайкин. – Вильямс. – 2006. – С. 107, 371–373, 396–398, 419–425.
8. Рутковская Д. Нейронные сети, генетические алгоритмы и нечеткие системы // Д. Рутковская, М. Пилиньский, Л. Рутковский. – ГЛ Телеком. – 2006. – С. 37–43.
9. Воронцов К.В. Лекции по методу опорных векторов // К.В. Воронцов // 2007. – С. 2–17.