Math-Net.Ru

Общероссийский математический портал

В. И. Арефьев, А. Б. Талалаев, С. В. Сорокин, А. В. Язенин, Метод классификации состояния воздушной обстановки на основе глубоких нейронных сетей и нечеткого вывода, *Нечеткие системы и мягкие вычисления*, 2018, том 13, выпуск 2, 113–125

DOI: <https://doi.org/10.26456/fssc46>

Использование Общероссийского математического портала Math-Net.Ru подразумевает, что вы прочитали и согласны с пользовательским соглашением

<http://www.mathnet.ru/rus/agreement>

Параметры загрузки:

IP: 54.210.77.194

26 апреля 2023 г., 18:03:29

МЕТОД КЛАССИФИКАЦИИ СОСТОЯНИЯ ВОЗДУШНОЙ ОБСТАНОВКИ НА ОСНОВЕ ГЛУБОКИХ НЕЙРОННЫХ СЕТЕЙ И НЕЧЕТКОГО ВЫВОДА

Арефьев В.И.^{*}, Талалаев А.Б.^{**}, Сорокин С.В.^{***}, Язенин А.В.^{***}

^{*}ЗАО «РТИС ВКО», г. Тверь

^{**}АО «Радиотехнический институт имени академика А.Л. Минца», г. Москва

^{***}Тверской государственный университет, г. Тверь

Поступила в редакцию 17.10.2018, после переработки 28.11.2018.

Предлагается метод классификации состояния воздушной обстановки (ВО). Его основой являются глубокая нейронная сеть, решающая задачу сокращения размерности входного вектора признаков, и машина нечеткого вывода, обеспечивающая оценку возможности соответствия вектора признаков каждой из оперативных ситуаций. Результатом работы классификатора являются возможности всех состояний воздушного обстановки в текущий момент времени. Работа классификатора демонстрируется на модельном примере.

Ключевые слова: состояние воздушной обстановки, классификация, теория возможностей, глубокая нейронная сеть, нечеткая (возможностная) величина, мягкие вычисления, нечеткий вывод.

Нечеткие системы и мягкие вычисления. 2018. Т. 13, № 2. С. 113–125.
<https://doi.org/10.26456/fssc46>

Введение

Проблема идентификации состояния воздушной обстановки может быть сформулирована как задача классификации состояния системы. Для ее решения используется информация, получаемая от технических средств, а также экспертная информация, как правило, с элементами неопределенности гибридного (возможностно-вероятностного) типа.

В этом случае наряду с вероятностным подходом для моделирования информации, представления экспертных знаний при принятии решений привлекается современная теория возможностей и нечетких систем, нейронные сети и генетические алгоритмы, то есть технологии мягких вычислений [1–3]. В статье описываются информационная система классификации и ее компоненты, разработанные в соответствии с данной концепцией.

1. Архитектура информационной системы анализа состояния воздушного обстановки

Данная работа продолжает исследования, начатые в [4, 5], посвященные применению математического аппарата мягких вычислений и базирующихся на них

Рис. 1: Архитектура информационной системы

информационных технологий для решения задач классификации состояния воздушной обстановки. Архитектура информационной системы представлена на Рис. 1.

Процедура принятия решений по классификации состояния воздушного пространства является, в общем случае, иерархической процедурой принятия решения с обратной связью. Конкретная конфигурация системы зависит от числа доступных на разных уровнях информационных источников. Основным блоком информационной системы является классификатор.

2. Структура классификатора и его работа

Классификатор обеспечивает необходимой информацией ЛПР (лицо, принимающее решение) для принятия решения (управления) на высшем уровне по результатам обработки информации, поступающей с нижнего уровня принятия решений. Входящая информация для него представляется в форме возможностей вскрытия всех оперативных ситуаций $\mu_i^m(t)$, $m \in M$. Значения возможностей объединяются в единый вектор и подаются на вход классификатора, см. Рис. 2.

Классификатор включает в себя глубокую нейронную сеть, решающую задачу сокращения размерности входного вектора признаков, и машину нечеткого вывода, обеспечивающую оценку возможностей принадлежности признаков к каждой из оперативных ситуаций. Результатом работы классификатора являются определенные им возможности η_i всех состояний воздушного пространства в текущий момент времени.

2.1. Сокращение размерности входного сигнала.

Работа классификатора начинается с сокращения размерности входного сигнала с помощью нейронной сети прямого распространения (см. Рис. 3).

Рис. 2: Структура классификатора

Рис. 3: Нейронная сеть прямого распространения

Архитектура нейронной сети прямого распространения описывается числом слоев нейронов и числом нейронов в каждом слое, а также функцией активации, используемой каждым нейроном.

При фиксированной архитектуре вычисляемая сетью функция определяется матрицами весов связей между нейронами и значением смещения для каждого нейрона. Для унификации расчетов смещение может быть представлено как вес дополнительной связи нейрона с фиксированным значением 1, добавляемым к вектору выходных значений предыдущего слоя.

Расчеты в нейронной сети прямого распространения проводятся послойно. На вход первому слою подается вектор входных значений, дополненный 1. Далее, для каждого нейрона всех последующих слоев вычисляется значение функции активации от взвешенной суммы выходов предыдущих слоев. В качестве функции активации используется ограниченная нулем линейная функция. Выход каждого слоя (кроме последнего) дополняется значением 1. Алгоритм сокращения

размерности нейронной сетью представлен в листинге 1.

Листинг 1. Алгоритм сокращения размерности нейронной сетью

Параметры:

- L – число слоев ИНС;
- n_l – число нейронов в слое l ;
- функция активации:

$$s(net) = \begin{cases} net, & net \geq 0; \\ 0, & \text{иначе;} \end{cases}$$
- расширенные матрицы весов:

$$W_l = (w_{ij}^{(l)}), i = \overline{1, n_{l-1} + 1}, j = \overline{1, n_l}.$$

Аргументы:

- $o^{(0)} = (\mu_1^1(t), \dots, \mu_I^k(t))$ – данные от источников.

Алгоритм:

1. Дополнить входной вектор единицей

$$\hat{o}^{(0)} = (o_1^{(0)}, \dots, o_{n_0}^{(0)}, 1).$$

2. Вычислить сетевую функцию:
 Для всех слоев l :

$$net_j^l = \sum_{i=1}^{n_{l-1}+1} w_{ij}^{(l)} \hat{o}_i^{(l-1)}, o_j^{(l)} = s(net_j^l), \hat{o}^{(l)} = (o_1^{(l)}, \dots, o_{n_l}^{(l)}, 1).$$

2.2. Нечеткий вывод

Сигнал уменьшенной размерности подается на вход системы нечеткого вывода, которая производит классификацию состояния воздушного пространства.

Нечеткий вывод опирается на базу правил, каждое из которых включает предпосылку в виде возможностного распределения, которое задается вектором модальных значений S , определяющим положение точки с максимальной возможностью, и матрицей A , определяющей ориентацию и «размеры» возможностной величины.

В классификаторе используется нечеткий вывод Сугено 1-го порядка, соответственно заключения каждого правила являются линейными функциями входных данных, параметры которых представлены вектором V .

Для осуществления нечеткого вывода сначала определяется уровень активации и вывод для каждого правила. Затем выходные значения разных правил объединяются с помощью взвешенной суммы. Алгоритм вычислений представлен в листинге 2.

Листинг 2. Алгоритм нечеткого вывода

Параметры:

- m – размер входа (число выходов ИНС);
- для всех правил r :
 - $c_r \in R^m$ – модальный вектор;
 - A_r – положительно определенная матрица $m \times m$;
 - $B_r \in R^{m+1}$ – вектор выходных параметров.

Аргументы:

- $x = o^{(L)}$ – результат вычислений последнего слоя ИНС.

Алгоритм:

1. Определение уровней активации правил.

Для всех правил r :

$$\omega_r = \exp \left(- \left(\sqrt{(x - c_r) A_r (x - c_r)} \right)^2 \right).$$

2. Определение выходов правил.

Для всех правил r :

$$y_r = \sum_i x_i b_i^r + b_0^r.$$

3. Определение результата нечеткого вывода:

$$y = \frac{\sum_r \omega_r y_r}{\sum_r \omega_r}.$$

3. Обучение классификатора

Перед использованием классификатора необходимо определить значения параметров, определяющих работу нейронной сети и машины нечеткого вывода. Этот процесс носит название обучения классификатора.

На первом этапе происходит определение весов связей нейронной сети. Для этого используется алгоритм обратного распространения ошибки, являющийся разновидностью алгоритма градиентного спуска [3].

После обучения нейронной сети определяются параметры машины нечеткого вывода. Данный этап основан на методе μ/E -оценки параметров возможных распределений [6].

3.1. Обучение нейронной сети

Обучение нейронной сети производилось методом обратного распространения ошибки (листинг 3). Перед началом алгоритма необходимо задать архитектуру нейронной сети и выбрать скорость обучения и число итераций алгоритма. Эти параметры определяются экспериментальным путем.

Листинг 3. Алгоритм обучения нейронной сети

Параметры:

- L – число слоев ИНС;
- n_l – число нейронов в слое l ;
- N – число итераций алгоритма;
- γ – скорость обучения.

Аргументы:

- $\{(o_t, s_t)\}$, $t = \overline{1, T}$ – мн-во обучающих примеров данных от источников o_t и соответствующих состояний воздушного пространства s_t .

Алгоритм:

1. Вычислить параметры близости данных:

$$p_{j|i} = \frac{\exp\left(-\frac{\|o_i - o_j\|^2}{2}\right)}{\sum_{k \neq i} \exp\left(-\frac{\|o_i - o_k\|^2}{2}\right)}, \quad p_{ij} = \frac{(p_{j|i} + p_{i|j})}{2T}, \quad i = \overline{1, T}, \quad j = \overline{1, T}.$$

2. Повторять N раз:

Для всех $t = \overline{1, T}$:

3. Провести прямое вычисление.

$$o^{(0)} = o_t$$

Для всех слоев $l = \overline{1, L}$:

$$net_j^{(l)} = \sum_{i=1}^{n+1} w_{ij}^{(l)} \hat{o}_i^{(l)}, \quad o^{(l)} = s\left(net_j^{(l)}\right), \quad D_l = \text{diag}\left(\frac{do_1^{(l)}}{dnet_1^{(l)}}, \dots, \frac{do_n^{(l)}}{dnet_n^{(l)}}\right).$$

4. Вычислить производную ошибки по весам.

$$q_{ij} = \frac{\left(1 + \|o_i^{(L)} - o_j^{(L)}\|^2\right)^{-1}}{\sum_{k \neq i} \left(1 + \|o_i^{(L)} - o_k^{(L)}\|^2\right)^{-1}}, \quad i = \overline{1, T}, \quad j = \overline{1, T},$$

$$\delta_i^{(L)} = 4 \sum_{j=\overline{1, T}} (p_{ij} - q_{ij}) (o_i^{(L)} - o_j^{(L)}) \left(1 + \|o_i^{(L)} - o_j^{(L)}\|^2\right)^{-1}.$$

Для всех слоев $l = \overline{L-1, 1}$: $\delta^{(l)} = D_l W_{l+1} \delta^{(l+1)}$.

5. Скорректировать матрицы весов.

Для всех слоев $l = \overline{1, L}$: $W_l = W_l - \gamma \delta^{(l)} \hat{o}^{(l)}$.

Для обучения была собрана база обучающих примеров, включающих примеры входных значений сети О (информация от источников) для разных состояний воздушного пространства S.

Алгоритм выполняется итерационно, несколько раз для каждого примера из обучающей выборки.

При обработке каждого примера сначала выполняется обычный расчет от

входного значения к выходу сети, затем обратный расчет – от выхода к входу, позволяющий вычислить частные производные итоговой ошибки по всем весам сети. После вычисления производной ошибки все веса корректируются на пропорциональную ей величину.

Используемая для обучения нейронной сети функция ошибки убывает в случае близкого расположения друг к другу проекций входных данных одного класса и возрастает при близком расположении проекций данных разных классов. Таким образом, минимизация этой функции способствует формированию сети, обеспечивающей проецирование многомерных входящих данных в выходное пространство с меньшей размерностью таким образом, что проекции данных, соответствующих разным состояниям воздушного пространства, образуют обособленные кластеры.

3.2. Обучение машины нечеткого вывода

Алгоритм обучения машины нечеткого вывода представлен в листинге 4.

Листинг 4. Алгоритм обучения машины нечеткого вывода

Параметры:

- $r \in R$ – параметр алгоритма кластеризации.

Аргументы:

- $X = \{x_{it} \mid i = \overline{1, n}; t = \overline{1, T}\}$ – выходы последнего слоя ИНС на обучающих примерах;
- $S = \{s_t \mid t = \overline{1, T}\}$ – состояние воздушного пространства на обучающих примерах.

Алгоритм:

1. Выделить кластеры:

$$CC = \text{subclust}([X, S], r), \quad C = \text{cmeans}([X, S], CC).$$

2. Построить предпосылки правил.

Для всех кластеров $C_r \in C$, $C_r \subseteq [X, S]$, $r = \overline{1, R}$:

$$c_r, A_r = \mu/E_estimation(C_r).$$

3. Построить заключения правил B_r , решив методом наименьших квадратов следующую систему уравнений:

$$\left\{ \begin{array}{l} \omega_{rt} = \exp \left(- \left(\sqrt{(x_t - c_r) A_r (x_t - c_r)} \right)^2 \right), \\ \left[\begin{array}{cccc} \frac{\omega_{00} x_{00}}{\sum_r \omega_{r0}} & \dots & \frac{\omega_{00} x_{m0}}{\sum_r \omega_{r0}} & \frac{\omega_{00}}{\sum_r \omega_{r0}} & \dots & \frac{\omega_{R0}}{\sum_r \omega_{r0}} \\ & & \vdots & & \ddots & \vdots \\ \frac{\omega_{0T} x_{0T}}{\sum_r \omega_{rT}} & \dots & \frac{\omega_{0T} x_{mT}}{\sum_r \omega_{rT}} & \frac{\omega_{0T}}{\sum_r \omega_{rT}} & \dots & \frac{\omega_{RT}}{\sum_r \omega_{rT}} \end{array} \right] \cdot [B_0 \dots B_R]^T = [s_t]. \end{array} \right.$$

Для обучения машины нечеткого вывода необходимо задать параметр близости r , используемый алгоритмом кластеризации.

На вход алгоритму подаются данные из обучающей выборки, входная часть от которых прошла проецирование с помощью нейронной сети. Алгоритм начинается с выделения кластеров с помощью метода К-средних. Для инициализации центров кластеров используется алгоритм субтрактивной кластеризации.

Каждый из полученных кластеров рассматривается как прототип для создания правил для машины нечеткого вывода. Параметры предпосылок правил определяются с помощью метода μ/E -оценки параметров вероятностных распределений [6]. Затем определяются параметры заключений правил. Эта задача сводится к решению системы линейных уравнений методом наименьших квадратов.

μ/E -оценка параметров вероятностных распределений основывается на соответствующей теореме, доказанной в [6]. Согласно этой теореме, для получения параметров распределения, описывающего множество точек, необходимо построить вокруг этого множества описанный эллипсоид минимального объема. Значения параметров распределения вычисляются через параметры такого эллипсоида.

4. Модельные расчеты

Проверка работоспособности классификатора была проведена на модельных данных. Было смоделировано поступление данных от двух источников по 14 оперативным ситуациям – всего 28 входных параметров (Таблица 1).

Таблица 1: Данные – наборы значений мер принадлежности мероприятий состоянию ВО

М	В1		В2		В3	
	И1	И2	И1	И2	И1	И2
1	0.8	0.7	0.8	0.3	0	0
2	0.8	0.7	0.8	0.2	0.9	0.2
3	0.1	0.1	0.7	0.28	0.1	0
4	0.2	0.2	0.8	0.3	0	0.1
5	0.2	0.2	0.7	0.3	0	0.1
6	0	0	0.8	0	0.8	0
7	0	0	0.2	0	0.9	0.1
8	0.8	0.76	0.8	0.4	0.8	0.4
9	0	0	0.1	0.1	0.95	0.1
10	0	0	0.2	0.25	0.8	0.25
11	0	0	0.3	0.2	0.8	0.6
12	0.8	0.7	0.8	0.3	0.9	0.3
13	0	0	0	0	0.9	0
14	0	0	0.9	0.1	0.9	0.1

Для обучения и проверки системы были использованы два разных набора данных по 500 элементов в каждом.

После обучения нейронной сети она отобразила эти примеры в три четко выраженных кластера в двумерном пространстве, соответствующих трем состояниям воздушного пространства (Рис. 4). Показаны выходы классификатора на

нескольких примерах данных, соответствующих разным состояниям воздушного пространства.

Рис. 4: Результаты обучения системы классификации

На Рис. 5 показаны результаты работы программы «Классификация состояния ВО» на данных, соответствующих первому (Рис. 5.а) и третьему (Рис 5.б) состояниям.

(а)

Исходные данные:						
	I1 B1	I2 B1	I1 B2	I2 B2	I1 B3	I2 B3
M1	0.8	0.7	0.8	0.3	0	0
M2	0.8	0.7	0.8	0.2	0.9	0.2
M3	0	0.1	0.7	0.28	0	0
M4	0	0.2	0.8	0.3	0	0.1
M5	0	0.2	0.7	0.3	0	0.1
M6	0	0	0.8	0	0.8	0
M7	0	0	0	0	0.9	0.1
M8	0.8	0.76	0.8	0.4	0.8	0.4
M9	0	0	0	0.1	0.95	0.1
M10	0	0	0.8	0.76	0.8	0.25
M11	0	0	0	0.2	0.8	0.6
M12	0.8	0.7	0.8	0.3	0.9	0.3
M13	0	0	0	0	0.9	0
M14	0	0	0.9	0.1	0.9	0.1

Вариант: 1 3
Расчитать Очистить

Результат:

1. C1 => 1; C2 => 0; C3 => 0; Определена воздушная ситуация 1
2. C1 => 0; C2 => 1; C3 => 0; Определена воздушная ситуация 2
3. C1 => 0; C2 => 0; C3 => 1; Определена воздушная ситуация 3

(б)

Рис. 5: Результаты работы программы Классификация состояния ВО

Заключение

Выбор варианта решения задачи классификации воздушной обстановки с использованием нейронных сетей с самообучением, основан на неоднородности входной информации и нестандартности действий противоборствующей стороны при изменении состояния воздушной обстановки. Обучение нейронной сети проводится путем накопления представительной выборки действий противоборствующей стороны в ходе обучения и тренировки воздушной компоненты его сил и средств, а также путем формирования представительной выборки с использованием моделирующих стендов по тем действиям, которые на учениях не отрабатываются.

Предложенный и реализованный программно алгоритм позволит своевременно и с требуемой достоверностью предоставить лицу принимающему решение соответствующие предложения.

Список литературы

- [1] Батыршин И.З., Недосекин А.О., Стецко А.А., Тарасов В.Б., Язенин А.В., Ярушкина Н.Г. Нечеткие гибридные системы. Теория и практика / под ред. Н.Г. Ярушкиной. М.: Физматлит, 2007. 208 с.

- [2] Язенин А.В. Основные понятия теории возможностей. Математический аппарат для принятия решений в условиях гибридной неопределенности. М.: Физматлит, 2016. 144 с.
- [3] Пегат А. Нечеткое моделирование и управление. М.: БИНОМ. Лаборатория знаний, 2013. 798 с.
- [4] Арефьев В.И., Петров М.О., Сорокин С.В., Талалаев А.Б., Язенин А.В. Информационная система классификации оперативной ситуации на основе технологий мягких вычислений // Труды III Всероссийской научно-технической конференции «РТИ Системы ВКО-2015». М.: МГТУ им. Н.Э. Баумана, 2015. С. 77–90.
- [5] Арефьев В.И., Петров М.О., Талалаев А.Б., Сорокин С.В., Язенин А.В. Классификация состояния системы на основе технологий мягких вычислений // Нечеткие системы и мягкие вычисления. 2016. Т. 11, № 1. С. 33–56.
- [6] Сорокина И.В., Сорокин С.В. К задаче оценки параметров многомерных возможностей распределений // Нечеткие системы и мягкие вычисления. 2013. Т. 8, № 2. С. 101–113.

Образец цитирования

Арефьев В.И., Талалаев А.Б., Сорокин С.В., Язенин А.В. Метод классификации состояния воздушной обстановки на основе глубоких нейронных сетей и нечеткого вывода // Нечеткие системы и мягкие вычисления. 2018. Т. 13, № 2. С. 113–125. <https://doi.org/10.26456/fssc46>

Сведения об авторах

1. Арефьев Владимир Игоревич

заместитель начальника отдела ЗАО «Радиотехнические и информационные системы воздушно-космической обороны».

170041, г. Тверь, ул. Зинаиды Коноплянниковой, д. 89, к. 1, ЗАО «РТИС ВКО». E-mail: arfulad@mail.ru

2. Талалаев Александр Борисович

главный конструктор АО «РТИ им. академика А.Л. Минца».

Россия, 127083, г. Москва, ул. 8-го Марта, д. 10, стр. 1.

3. Сорокин Сергей Владимирович

доцент кафедры информационных технологий Тверского государственного университета.

Россия, 170100, г. Тверь, ул. Желябова, д. 33, ТвГУ. E-mail: sergey@tversu.ru

4. Язенин Александр Васильевич

декан факультета прикладной математики и кибернетики Тверского государственного университета.

Россия, 170100, г. Тверь, ул. Желябова, д. 33, ТвГУ.
E-mail: Yazenin.AV@tversu.ru

CLASSIFICATION OF AIR SITUATION USING DEEP NEURAL NETWORKS AND FUZZY INFERENCE

Arefiev Valdimir Igorevich

Deputy Head of department, CJSC "RTIS VKO"
Russia, 170041, Tver, Zinaidy Konopliannikovoy str., 89/1.
E-mail: arfolad@mail.ru

Talalaev Alexander Borisovich

Chief Designer at JSC "RTI named after Academician A.L. Mints"
Russia, 127083, Moscow, 8-go Marta str., 10/1.

Sorokin Sergey Vladimirovich

Associate professor at Information Technology department, Tver State University
Russia, 170100, Tver, Zhelyabova str., 33, TverSU.
E-mail: sergey@tversu.ru

Yazenin Alexander Vasilyevich

Dean of Applied Mathematics and Cybernetics faculty, Tver State University
Russia, 170100, Tver, Zhelyabova str., 33, TverSU.
E-mail: Yazenin.AV@tversu.ru

Received 17.10.2018, revised 28.11.2018.

A method for classifying the state of the air situation is proposed. Its basis is a deep neural network that solves the problem of reducing the dimension of the input vector of features, and a fuzzy inference machine that provides an assessment of the possibility of matching the feature vector of each of the operational situations. The result of the classifier is the possibilities of all states of the air situation at the current time. The classifier is demonstrated on a model example.

Keywords: air situation state, classification, possibility theory, deep neural network, fuzzy variable, soft computing, fuzzy inference.

Citation

Arefiev V.I., Talalaev A.B., Sorokin S.V., Yazenin A.V., "Classification of air situation using deep neural networks and fuzzy inference", *Nechetkie Sistemy i Myagkie Vychisleniya [Fuzzy Systems and Soft Computing]*, **13**:2 (2018), 113–125 (in Russian). <https://doi.org/10.26456/fssc46>

References

- [1] Batyrshin I.Z., Nedosekin A.O., Stetsko A.A., Tarasov V.B., Yazenin A.V., Yarushkina N.G., *Nechetkie gibridnye sistemy. Teoriya i praktika [Fuzzy Hybrid Systems. Theory and Practice]*, ed. N.G. Yarushkina, Fizmatlit Publ., Moscow, 2007 (in Russian), 208 pp.
- [2] Yazenin A.V., *Osnovnye ponyatiya teorii vozmozhnostej. Matematicheskij apparat dlya prinyatiya reshenij v usloviyakh gibridnoj neopredelennosti [Basic concepts of the theory of possibilities. Mathematical decision-making apparatus in a hybrid uncertainty]*, Fizmatlit Publ., Moscow, 2016 (in Russian), 144 pp.

- [3] Piegat A., *Fuzzy Modeling and Control*, Springer-Verlag, Berlin, Heidelberg, 2001, 725 pp.
- [4] Arefev V.I., Petrov M.O., Sorokin S.V., Talalaev A.B., Yazenin A.V., “Information system for classifying operational situation based on soft computing technologies”, *Trudy III Vserossijskoj nauchno-tekhnicheskoy konferentsii "RTI Sistemy VKO-2015" [Proceedings of the III All-Russian Scientific and Technical Conference "RTI Systems VKO-2015"]*, Bauman MSTU, Moscow, 2015, 77–90 (in Russian).
- [5] Arefiev V.I., Petrov M.O., Talalaev A.B., Sorokin S.V., Yazenin A.V., “Classification methods of system condition based on soft computing technology”, *Nechetkie Sistemy i Myagkie Vychisleniya [Fuzzy Systems and Soft Computing]*, **11:1** (2016), 33–56 (in Russian).
- [6] Sorokina I.V., Sorokin S.V., “On parameters estimation for multidimensional possibility distributions”, *Nechetkie Sistemy i Myagkie Vychisleniya [Fuzzy Systems and Soft Computing]*, **8:2** (2013), 101–113 (in Russian).