

УДК 681.3.07

А.В. Шматко¹, Е.А. Голубничая²

¹Университет гражданской защиты Украины, Харьков

²Харьковский машиностроительный колледж, Харьков

АНАЛИЗ ЭФФЕКТИВНОСТИ НЕЧЕТКИХ НЕЙРОННЫХ СЕТЕЙ В ЗАДАЧАХ ПРОГНОЗИРОВАНИЯ ЧРЕЗВЫЧАЙНЫХ СИТУАЦИЙ ТЕХНОГЕННОГО ХАРАКТЕРА

В работе рассмотрены нечеткие нейронные сети (ННС) с выводом Мамдани, Цукамото и Сугено для задач прогнозирования чрезвычайных ситуаций техногенного характера. Проведены сравнительные экспериментальные исследования ННС с различными алгоритмами вывода. Определен эффективный алгоритм нечеткого вывода для данного класса задач.

нечеткие нейронные сети, нечеткие нейронные контроллеры, прогнозирование чрезвычайных ситуаций, функции принадлежности

Введение

Постановка проблемы. Прогнозирование пожаров на предприятиях, организациях и учреждениях Украины является достаточно актуальной задачей, которая требует постоянного и эффективного решения. До сих пор при ее решении не использовались нечеткие нейронные сети (ННС), которые по сравнению с обыкновенными ННС имеют ряд достоинств, таких как

- возможность работы с неполными и неопределенными данными;
- возможность учета знаний экспертов в виде нечетких предикатных правил вывода типа IF-THEN-ELSE.

Поэтому, научная проблема как раз и заключается в рассмотрении возможностей ННС к прогнозированию пожаров на различных объектах.

Анализ последних достижений и публикаций. В последние годы появилось большое количество публикаций, посвященных исследованиям систем с нечеткой логикой и ННС в задачах управления, аппроксимации, классификации и распознава-

ния образов [1, 2, 5, 6]. К задачам прогнозирования ННС стали использоваться совсем недавно. Например, в работе [3] проведен анализ нечетких контроллеров (НК) с выводом Мамдани и Цукамото в задачах макроэкономического прогнозирования с треугольными функциями принадлежности. В работе [4] исследована ННС ANFIS с выводом Сугено в задачах прогнозирования макроэкономических параметров. Анализ литературы показывает, что практически отсутствуют работы, посвященные исследованию применения ННС в задачах прогнозирования чрезвычайных ситуаций техногенного характера.

Формулировка цели статьи. В настоящей работе проводится сравнительный анализ ННС с различными алгоритмами и функциями принадлежности применительно к задачам прогнозирования чрезвычайных ситуаций техногенного характера с целью определения наиболее адекватного метода для этого класса задач прогнозирования, а также разрабатывается алгоритм обучения НК Мамдани и Цукамото для гауссовских функций принадлежности (ФП).

1. Алгоритмы нечеткого логического вывода

Рассмотрим следующие наиболее употребительные алгоритмы нечеткого вывода, считая, для простоты, что базу знаний организуют два нечетких правила вида:

П₁: если x есть A_1 и y есть B_1 , то z есть C_1 ,

П₂: если x есть A_2 и y есть B_2 , то z есть C_2 ,

где x и y – имена входных переменных; z – имя переменной вывода; $A_1, B_1, C_1, A_2, B_2, C_2$ – некоторые заданные функции принадлежности.

При этом четкое значение z_0 необходимо определить на основе приведенной информации и четких значений x_0 и y_0 .

Алгоритм Мамдани. В рассматриваемой ситуации математически алгоритм может быть описан следующим образом:

1. Введение нечеткости. Находятся степени истинности для предпосылок каждого правила

$$A_1(x_0), A_2(x_0), B_1(y_0), B_2(y_0).$$

2. Логический вывод. Находятся уровни "отсечения" для предпосылок каждого правила (с использованием операции *МИНИМУМ*)

$$\alpha_1 = A_1(x_0) \wedge B_1(y_0);$$

$$\alpha_2 = A_2(x_0) \wedge B_2(y_0),$$

где \wedge обозначена операция логического минимума (*min*). Затем находятся "усеченные" функции принадлежности

$$C_1' = (\alpha_1 \wedge C_1(z)); C_2' = (\alpha_2 \wedge C_2(z)).$$

3. Композиция. Производится объединение найденных усеченных функций с использованием операции *МАКСИМУМ* (*max*, обозначенные далее \vee), что приводит к получению итогового нечеткого подмножества для переменной выхода с функцией принадлежности

$$\mu_{\text{sum}}(z) = C(z) = C_1'(z) \vee C_2'(z) = ((\alpha_1 \wedge C_1(z)) \vee (\alpha_2 \wedge C_2(z))).$$

4. Приведение к четкости. Проводится для нахождения z_0 , например, центроидным методом.

Алгоритм Цукамото. Исходные посылки такие же, как и у предыдущего алгоритма, но здесь предполагается, что функции $C_1(z), C_2(z)$ монотонные.

1. Введение нечеткости (как в алгоритме Мамдани).

2. Нечеткий вывод. Сначала находятся уровни "отсечения" α_1 и α_2 (как в алгоритме Мамдани), а затем решения уравнений

$$\alpha_1 = C_1(z_1), \alpha_2 = C_2(z_2)$$

определяются четкие значения (z_1 и z_2) для каждого исходного правила.

3. Определяется четкое значение переменной вывода (как взвешенное среднее z_1 и z_2)

$$z_0 = \frac{\alpha_1 z_1 + \alpha_2 z_2}{\alpha_1 + \alpha_2}.$$

Алгоритм Сугено. Сугено и Такаги использовали набор правил в следующей форме (как и ранее, приведем пример двух правил):

П₁: если x есть A_1 и y есть B_1 , то $z_1 = a_1 x + b_1 y$,

П₂: если x есть A_2 и y есть B_2 , то $z_2 = a_2 x + b_2 y$.

Описание алгоритма

1. Введение нечеткости (как в алгоритме Мамдани).

2. Нечеткий вывод.

Находятся $\alpha_1 = A_1(x_0) \wedge B_1(y_0)$, $\alpha_2 = A_2(x_0) \wedge B_2(y_0)$ и индивидуальные выходы правил

$$\dot{z}_1 = a_1 x_0 + b_1 y_0;$$

$$\dot{z}_2 = a_2 x_0 + b_2 y_0.$$

3. Определяется четкое значение переменной выхода

$$z_0 = \frac{\alpha_1 \dot{z}_1 + \alpha_2 \dot{z}_2}{\alpha_1 + \alpha_2}.$$

Градиентный алгоритм обучения ННС с гауссовскими функциями принадлежности. Предложенный в работе [6] алгоритм обучения НК Мамдани носит эмпирический характер, формулы для настройки параметров функций принадлежности теоретически необоснованны. Это связано с тем, что в НК Мамдани и Цукамото используются треугольные ФП, а пересечение условий правил берется в форме *min*. В результате получаемые ФП оказываются не дифференцируемыми. В связи с этим целесообразно разработать аналитический алгоритм обучения, сходимость которого была бы строго доказана, для чего необходимо перейти к гауссовским ФП для условий и правил. Итак, пусть ФП i -го μ -модуля, связанного с

правилом R_k , описывается выражением

$$\mu_{ik}(x_i) = \exp\left\{-\frac{(x_i - a_{ik})^2}{2\sigma_{ik}^2}\right\},$$

где a_{ik}, σ_{ik} – параметры, подлежащие настройке в процессе обучения, и ФП μ_k -модуля имеют аналогичный вид

$$\mu_k(y_i) = \exp\left\{-\frac{(y_i - a_k)^2}{2\sigma_k^2}\right\}.$$

При этом пересечение условий правил задается в виде произведения

$$\alpha_k = \prod_{i=1}^n \mu_{ik}(x_i) = \exp\left\{-\frac{(x_i - a_{ik})^2}{2\sigma_{ik}^2}\right\}.$$

Допустим, что дефаззификация происходит по центроидному методу, тогда общий выход

$$z_0 = \sum_k z_k \alpha_k / \sum_k \alpha_k.$$

Пусть для определения следствия правила используются монотонные ФП, и z_k определяется путем решения уравнения (контроллер Цукамото)

$$C_k(z_k) = \alpha_k, \quad (1)$$

где $C_k(z_k) = \exp\left\{-\frac{(z_k - a_k)^2}{2\sigma_k^2}\right\}$.

Тогда, решая уравнение (1) находим два корня:

$$Z_k = a_k \pm \sqrt{2 \ln \frac{1}{\alpha} \sigma_k}.$$

Первый корень $Z_{1k} = a_k - \sqrt{2 \ln \frac{1}{\alpha} \sigma_k}$ находится на монотонно возрастающем участке кривой $C_k(z_k)$, а второй $Z_{2k} = a_k + \sqrt{2 \ln \frac{1}{\alpha} \sigma_k}$ – на монотонно убывающем.

Пусть критерий $E(z) = \frac{1}{2}(z_0 - z^*)^2 \rightarrow \min$, где z^* – фактический выход; z_0 – выход НК.

Находим производные

$$\frac{\partial E}{\partial a_k} = \frac{\partial E_0}{\partial z_0} \frac{\partial z_0}{\partial z_k} \frac{\partial z_k}{\partial a_k} = + (z_0 - z^*) \frac{\alpha_k}{\sum_{k=1}^K \alpha_k};$$

$$\frac{\partial E}{\partial \sigma_k} = \frac{\partial E_0}{\partial z_0} \frac{\partial z_0}{\partial z_k} \frac{\partial z_k}{\partial \sigma_k} = - (z_0 - z^*) \frac{\alpha_k}{\sum_{k=1}^K \alpha_k} \sqrt{2 \ln \frac{1}{\alpha} \alpha_k}$$

на монотонно возрастающем участке кривой ФП μ_k и

$$\frac{\partial E}{\partial \sigma_k} = + (z_0 - z^*) \left(\alpha_k / \sum_{k=1}^K \alpha_k \right) \sqrt{2 \ln \frac{1}{\alpha} \alpha_k}$$

на монотонно убывающем.

Для входных μ -модулей

$$\frac{\partial E}{\partial a_{ik}} = \frac{\partial E_0}{\partial z_0} \frac{\partial z_0}{\partial z_k} \frac{\partial z_k}{\partial a_{ik}} = (z_0 - z^*) \alpha_k \times \left(z_k \sum_{k=1}^K \alpha_k - \sum_k z_k \alpha_k \right) / \left(\sum_{k=1}^K \alpha_k \right)^2 \frac{(x_i - a_{ik})}{\sigma_{ik}^2};$$

$$\frac{\partial E}{\partial \sigma_{ik}} = \frac{\partial E_0}{\partial z_0} \frac{\partial z_0}{\partial z_k} \frac{\partial z_k}{\partial \sigma_{ik}} = (z_0 - z^*) \alpha_k \times \left(z_k \sum_{k=1}^K \alpha_k - \sum_k z_k \alpha_k \right) / \left(\sum_{k=1}^K \alpha_k \right)^2 \frac{(x_i - a_{ik})^2}{\sigma_{ik}^3};$$

и тогда градиентный алгоритм обучения ННС Мамдани выглядит следующим образом:

а) для выходных модулей

$$a_k(n+1) = a_k(n) - \gamma_n \frac{\partial E}{\partial a_k} = a_k(n) - \gamma_n (z_0 - z^*) \alpha_k / \sum_{k=1}^K \alpha_k;$$

$$\sigma_k(n+1) = \sigma_k(n) - \gamma_n \frac{\partial E}{\partial \sigma_k} =$$

$$= \sigma_k(n) - \gamma_n (z_0 - z^*) \left(\alpha_k / \sum_{k=1}^K \alpha_k \right) \sqrt{2 \ln \frac{1}{\alpha} \alpha_k};$$

б) для входных μ -модулей

$$a_k(n+1) = a_{ik}(n) - \gamma_n \frac{\partial E}{\partial a_{ik}};$$

$$\sigma_k(n+1) = \sigma_{ik}(n) - \gamma_n \frac{\partial E}{\partial \sigma_{ik}},$$

где γ_n – размер шага.

Для сходимости метода необходимо, чтобы выполнялись стандартные условия алгоритма обучения в случайной среде [5]:

$$1) \gamma_n \rightarrow 0, n \rightarrow \infty; 2) \sum_{n=0}^{\infty} \gamma_n = \infty; 3) \sum_{n=0}^{\infty} \gamma_n^2 < \infty.$$

2. Численные исследования ННС в задачах прогнозирования чрезвычайных ситуаций техногенного характера

Исходные данные для исследования приведены в виде статистических данных (табл. 1). Данные взяты из сайта Министерства по вопросам чрезвычайных ситуаций Украины (www.mns.gov.ua).

Таблица 1

Анализ данных о пожарах и загораниях на предприятиях, организациях и учреждениях (2004 г.)

№	Название области	2004 год	ОГС	ОКС	ОЧС	ОКолС	ОСС
1	АР Крым	83	0,51	3,91	4,33	2,03	0,00
2	Винницкая	145	2,86	3,91	5,43	3,54	0,00
3	Волинская	66	1,52	0,78	1,19	3,54	0,00
4	Днепропетровская	196	1,52	11,72	7,80	6,50	9,09
5	Донецкая	504	19,70	4,69	15,44	15,11	3,03
6	Житомирская	79	1,85	3,13	1,61	3,46	0,00
7	Закарпатская	48	0,67	3,91	2,37	0,84	0,00
8	Запорожская	203	5,56	6,25	4,92	7,85	33,33
9	Ив.-Франковская	61	1,18	3,13	2,46	1,52	6,06
10	Киевская	49	0,34	3,13	1,78	1,77	3,03
11	Кировоградская	50	1,52	3,13	1,61	1,52	0,00
12	Луганская	219	10,77	3,91	7,12	5,40	3,03
13	Львовская	111	3,54	0,00	3,48	4,14	0,00
14	Николаевская	96	3,37	1,56	3,56	2,45	9,09
15	Одесская	74	2,19	3,91	2,63	1,94	6,06
16	Полтавская	95	3,54	2,34	2,97	3,04	0,00
17	Ровенская	67	1,35	1,56	2,88	1,94	0,00
18	Сумская	59	2,19	0,78	1,44	2,36	0,00
19	Тернопольская	79	2,19	2,34	2,46	2,87	0,00
20	Харьковская	184	8,08	2,34	5,17	5,65	0,00
21	Херсонская	98	4,04	10,94	3,39	1,43	9,09
22	Хмельницкая	73	1,68	0,00	2,80	1,94	0,00
23	Черкасская	91	0,67	10,94	2,88	2,62	0,00
24	Черновицкая	72	2,53	2,34	1,87	2,62	0,00
25	Черниговская	58	2,36	0,78	1,02	2,53	0,00
26	г. Киев	299	13,80	7,03	5,77	10,63	15,15
27	г. Севастополь	34	0,51	1,56	1,61	0,76	3,03
Всего по Украине		3193					

Замечание: ОГС – показатель количества пожаров и загораний на объектах государственной собственности; ОКС – показатель количества пожаров и загораний на объектах коммунальной собственности; ОЧС – показатель количества пожаров и загораний на объектах частной собственности; ОКолС – показатель количества пожаров и загораний на объектах коллективной собственности; ОСС – показатель количества пожаров и загораний на объектах смешанной собственности.

Выполним прогнозирование показателя ОГС по известным данным. При этом исследуем различные алгоритмы нечеткого вывода – Мамдани, Цукамото и Сугено с различными функциями принадлежности нечетких множеств.

Для построения базы правил необходимо определить значимые переменные и их лаги. В качестве степени взаимосвязи между входными переменными x_1, x_2, \dots, x_n и выходной переменной Y используется коэффициент корреляции R , по значению которого отбирались существенные переменные.

Выполним исследования эффективности прогнозирования и сравним результаты, полученные с помощью следующих нечетких нейронных контроллеров (ННК):

- Цукамото с линейными функциями принадлежности;
- Цукамото с монотонными функциями принадлежности;
- Мамдани с функциями принадлежности гауссовской формы;
- нейронная сеть ANFIS.

В табл. 2 приведены сравнительные результаты прогнозирования показателя, полученные различными методами нечеткого логического вывода, а графики сравнения прогнозируемых значений и реальных данных – на рис. 1

Как видно из табл. 2, все предложенные алгоритмы справились с задачей прогнозирования. Наилучший результат получен при использовании контроллера Мамдани с гауссовскими ФП. Среднее отклонение (СО) этого алгоритма составляет 0,04.

Далее, по качеству прогноза идет контроллер Цукамото с монотонной ФП и контроллер Цукамото с линейной ФП, причем монотонные функции

Таблица 2

Результаты прогнозирования параметра ОГС различными алгоритмами

Реальное значение	Сеть ANFIS		ННК Цукамото с линейной ФП		ННК Цукамото с монотонной ФП		ННК Мамдани с гауссовским ФП	
	прогноз	ошибка	прогноз	ошибка	прогноз	ошибка	прогноз	ошибка
0,51	0,73	0,22	0,69	0,18	0,69	0,18	0,67	0,16
2,86	3,57	0,71	3,11	0,25	3,10	0,24	2,92	0,06
1,52	1,69	0,17	1,84	0,32	1,82	0,3	1,64	0,12
1,52	1,96	0,44	1,76	0,24	1,73	0,21	1,55	0,03
19,70	19,78	0,08	20,00	0,3	19,99	0,29	19,76	0,06
1,85	1,92	0,07	2,00	0,15	2,00	0,15	1,95	0,10
0,67	1,64	0,97	1,34	0,67	1,23	0,56	0,74	0,07
5,55	6,38	0,82	6,04	0,48	6,00	0,44	5,61	0,05
1,19	1,92	0,74	1,69	0,51	1,65	0,47	1,34	0,16
0,34	1,10	0,76	0,86	0,52	0,84	0,5	0,46	0,12
	CO = 0,30		CO = 0,15		CO = 0,13		CO = 0,04	

принадлежности дают более лучший результат, чем линейные (CO = 0,13 и CO = 0,15 соответственно).

Это дает основание допустить, что при выборе более удачного вида функции принадлежности можно улучшить результат прогноза.

Худший результат прогноза показала сеть ANFIS (CO = 0,30). Такие результаты объясняются тем, что в ней не настраиваются параметры функций выходных правил.




Рис. 1. График сравнения прогнозных и реальных значений прогнозируемого параметра

3. Прогнозирование количества пожаров и загораний на предприятиях, организациях и учреждениях

В ходе эксперимента установлено, что наиболее оптимальным является использование трех термов и пяти правил обучения, так как при таких параметрах получаем оптимальное средне-квадратичное отклонение и наименьшее время обучения. Обучение параметров ФП производилось градиентным методом с шагом обучение 0,04.

В табл. 3 представлены результаты прогнозирования параметра ОКС с применением различных ННК и ННС, а на рис. 2 – результаты сравнения полученных отклонений.

Таблица 3

Результаты прогноза параметра ОКС с использованием различных ННК и ННС

Реальное значение	ННК Мамдани для ФП Гаусса		ННК Цукамото для ФП Гаусса		ННК Цукамото с треугольными ФП		ННС Сугено для ФП Гаусса		ННС Сугено для треугольных ФП	
	Прогноз	Отклонение	Прогноз	Отклонение	Прогноз	Отклонение	Прогноз	Отклонение	Прогноз	Отклонение
3,91	4,04	0,13	4,18	0,27	4,29	0,38	4,23	0,32	4,31	0,4
3,91	4,07	0,16	4,14	0,23	4,24	0,33	4,27	0,36	4,30	0,39
0,78	1,04	0,26	1,08	0,3	1,13	0,35	1,16	0,38	1,17	0,39
11,72	11,83	0,11	11,97	0,25	11,99	0,27	12,01	0,29	12,05	0,33
4,69	4,81	0,12	5,03	0,34	5,07	0,38	5,08	0,39	5,14	0,45
3,13	3,31	0,18	3,36	0,23	3,50	0,37	3,44	0,31	3,57	0,44
3,91	4,13	0,22	4,28	0,37	4,33	0,42	4,31	0,4	4,40	0,49
6,25	6,40	0,15	6,42	0,17	6,50	0,25	6,49	0,24	6,59	0,34
3,13	3,24	0,11	3,36	0,23	3,50	0,37	3,38	0,25	3,40	0,27
3,13	3,30	0,17	3,38	0,25	3,40	0,27	3,41	0,28	3,47	0,34
3,13	3,28	0,15	3,32	0,19	3,41	0,28	3,34	0,21	3,44	0,31
3,91	4,11	0,2	4,13	0,22	4,18	0,27	4,16	0,25	4,21	0,3
0,00	0,23	0,23	0,27	0,27	0,33	0,33	0,30	0,3	0,36	0,36
1,56	1,72	0,16	1,78	0,22	1,88	0,32	1,86	0,3	1,94	0,38
	CO =		CO =		CO =		CO =		CO =	
	0,1679		0,2529		0,3279		0,3057		0,3707	




Рис. 2. Графики сравнения отклонений при прогнозировании различными алгоритмами

Анализ ошибок прогнозирования для ННК Цукамото с треугольной и гауссовской ФП показал, что лучшим оказался контроллер Цукамото с гауссовской ФП: CO = 0,2529, а средняя ошибка прогноза не превысила 6,67%. Анализ полученных данных показывает, что лучшим является контроллер Сугено с гауссовскими ФП – CO = 0,3057.

Как демонстрируют приведенные в табл. 3 результаты, наилучшим, хотя и с небольшим отрывом, оказался контроллер Мамдани с гауссовской ФП. Его CO составляет всего 0,1679. Дальше по качеству прогноза идет контроллер Цукамото, причем гауссовские ФП дают немного лучший результат, чем треугольные. Но в целом их прогнозы очень близки (CO = 0,2529 и CO = 0,3279, соответственно). Это дает основание допустить, что подбор еще более удачного вида функций принадлежности даст возможность повысить результаты прогноза.

Выводы

1. Рассмотрены ННС с логическим вводом Мамдани, Цукамото и Сугено.
2. Описан алгоритм обучения ННС с функциями принадлежности гауссовского типа с выводом Мамдани и Цукамото.
3. Проведены численные исследования применения ННС в задачах прогнозирования чрезвычайных ситуаций техногенного характера и выполнен анализ их эффективности.
4. Сравнительный анализ точности прогнозирования рассмотренных методов показал, что наилучшими, для прогнозирования чрезвычайных ситуаций, является ННК Мамдани с гауссовскими ФП наихудшем – ННС ANFIS.
5. Проведенные исследования показали большие потенциальные возможности ННС и подтвердили их эффективность в задачах прогнозирования чрезвычайных ситуаций техногенного характера.

Список литературы

1. Круглов В.В., Борисов В.В. Гибридные нейронные сети. – М.: Горячая линия - Телеком, 2002. – 382 с.
2. Сетлак Г. Интеллектуальные системы поддержки принятия решений. – Киев: Логос, 2004. – 251 с.
3. Исследование нечетких нейронных сетей в задачах макроэкономического прогнозирования / Ю.П. Зайченко, Ф. Севаев и др. // Системні дослідження та інформаційні технології. – 2004. – № 2. – С. 70-86.
4. Зайченко Ю.П., Севаев Ф. Исследование эффективности нечеткой нейронной сети ANFIS в задачах макроэкономического прогнозирования // Системні дослідження та інформаційні технології. – 2005. – № 1. – С. 100-112.
5. Зайченко Ю.П. Исследование операций. – К.: Слово, 2003. – 688 с.
6. Nauck D., Klawonn F., Kruse R. Foundations of Neuro-Fuzzy Systems. – John Wiley & Sons, 1997. – 305 p.

Поступила в редколлегию 15.12.2006

Рецензент: д-р техн. наук, доцент С.В. Листровой, Харьковская академия железнодорожного транспорта, Харьков.

