

УДК 621.396

К.А. Польщиков¹, Е.Н. Кубракова², В.А. Краснобаев²¹Донбасская государственная машиностроительная академия, Краматорск²Полтавский национальный технический университет им. Юрия Кондратюка, Полтава

МОДЕЛЬ НЕЙРО-НЕЧЕТКОГО ПРОГНОЗИРОВАНИЯ СРЕДНЕЙ ИНТЕНСИВНОСТИ ПОСТУПЛЕНИЯ ЗАПРОСОВ НА ПЕРЕДАЧУ ПОТОКОВ РЕАЛЬНОГО ВРЕМЕНИ ПО КАНАЛУ ТЕЛЕКОММУНИКАЦИОННОЙ СЕТИ

В статье предложена модель прогнозирования параметров телекоммуникационной сети, осуществляющей передачу потоков реального времени, основанная на использовании нечеткой нейронной сети, функционирующей в соответствии с алгоритмом Сугено первого порядка.

Ключевые слова: нечеткая нейронная сеть, алгоритм Сугено, трафик реального времени.

1. Проблема нейро-нечеткого прогнозирования параметров трафика реального времени

В настоящее время большинство информационных потоков, передаваемых в современных телекоммуникационных сетях с коммутацией пакетов (голос, видео) образуют мультимедийный трафик. Интенсивность передачи информации, инициированная работой соответствующих программных средств в реальном времени является достаточно высокой и близкой к постоянному значению, потому такой вид трафика часто называют потоковым или трафиком реального времени

Интенсивность поступления от пользователей запросов на передачу потоков реального времени изменяется случайным образом. При случайном возрастании этой интенсивности в сети наблюдается временный дефицит канальных ресурсов. Это обуславливает появление отказов в обслуживании запросов, которые поступили от пользователей. При снижении указанной интенсивности уменьшается сетевая нагрузка, каналы сети работают в недогруженном режиме, и наблюдаются паузы в их использовании. Таким образом, каналы современных телекоммуникационных сетей нагружаются неравномерно во времени, в результате чего используются неэффективно [1].

Чтобы сгладить поток запросов на передачу потоков реального времени, которые поступают в сеть, целесообразно в условиях дефицита канальных ресурсов (сетевых перегрузок) осуществлять буферизацию этих запросов. При этом важной задачей является выбор максимального количества запросов, которые могут находиться в очереди на передачу потоков реального времени по каналу телекоммуникационной сети. Рост этой величины, с одной стороны, улучшает качество обслуживания пользователей, потому что в этом случае большое количество запросов может находиться в очереди на обслужи-

вание и меньшему числу пользователей будет отказано в обслуживании. С другой стороны, чем больше запросов может находиться в очереди, тем больше времени пользователям придется ждать обслуживания своих запросов, находящихся в очереди, что негативно скажется на качестве их обслуживания. Математическая модель для оценки качества обслуживания запросов на передачу потоков реального времени опубликована в [2].

2. Анализ последних исследований в области нейро-нечеткого прогнозирования параметров трафика реального времени

Анализ результатов исследований показал, что качественное обслуживание запросов на передачу потоков реального времени может быть достигнуто за счет предварительного резервирования канальных ресурсов.

Однако в научно-технической литературе вопросам эффективного резервирования ресурсов уделяется недостаточное внимание. Для рационального управления размером емкости буферизованных запросов необходимо иметь данные о том, какие значения будет принимать величина интенсивности поступления запросов на передачу потоков реального времени по каналу телекоммуникационной сети. Располагая этими данными, можно с достаточной точностью спрогнозировать загруженность соответствующих каналов сети и выбрать такое значение емкости буферизованных запросов, при котором будет обеспечена эффективная передача потоков реального времени.

3. Постановка задачи

Целью статьи является разработка математической модели прогнозирования интенсивности поступления запросов на передачу потоков реального времени по каналу телекоммуникационной сети.

4. Разработка математической модели нейро-нечеткого прогнозирования средней интенсивности поступления запросов на передачу потоков реального времени

Для прогнозирования интенсивности поступления запросов на передачу потоков реального времени по каналу телекоммуникационной сети в течение определенного интервала времени τ_i (выходной величины $\tilde{\lambda}_i$) предлагается использовать нечеткую нейронную сеть (рис. 1), на вход которой подаются измеренные в течение четырех предыдущих тактов значения интенсивности поступления запросов на передачу (входных величин λ_{i-4} , λ_{i-3} , λ_{i-2} и λ_{i-1}).




Рис. 1. Величины на входе и выходе нечеткой нейронной сети

Применение такой нечеткой нейронной сети положено в основу модели прогнозирования интенсивности поступления запросов на передачу потоков реального времени по каналу телекоммуникационной сети.

Указанный процесс прогнозирования включает выполнение следующих процедур:

- 1) в течение каждого текущего такта измеряется загрузка компьютерной системы;
- 2) на вход нечеткой нейронной сети подаются значения величин λ_{i-4} , λ_{i-3} , λ_{i-2} и λ_{i-1} ;

3) на основе выполнения нейро-нечеткого вывода вычисляется значение прогнозируемой величины $\tilde{\lambda}_i$;

Построение нечеткой нейронной сети целесообразно осуществлять в соответствии с методикой [3], предполагающей выполнение следующих этапов:

- 1) выбор алгоритма нечеткого вывода;
- 2) определение функций принадлежности для входных величин: выбор количества функций принадлежности, а также формы функций принадлежности;
- 3) выбор алгоритма обучения нечеткой нейронной сети;
- 4) создание обучающей выборки для настройки параметров нечеткой нейронной сети;
- 5) выбор количества циклов для обучения нечеткой нейронной сети;
- 6) настройка параметров (обучение) нечеткой нейронной сети.

Нечеткая нейронная сеть должна быть максимально простой, но при этом обеспечивать достаточное качество прогноза. С учетом этих критериев выбраны следующие параметры синтезируемой нейро-нечеткой системы: алгоритм нечеткого вывода – Су-гено 1-го порядка [4], количество функций принадлежности для каждой входной величины – 2, форма функций принадлежности для каждой входной величины – треугольная, алгоритм обучения нейронов – алгоритм обратного распространения ошибки [5].

Для создания обучающей выборки был осуществлен мониторинг загрузки реальной компьютерной системы в течение интервала времени, включающего 100 тактов по 1 мин каждый. Продолжительность одного такта выбрана с учетом времени, необходимого для оценки интенсивности поступающих запросов на передачу потоков реального времени. В результате получена реализация исследуемого случайного процесса, представленная на рис. 2.




Рис. 2. Значения λ_i , измеренные в процессе мониторинга реальной сети

На основе измеренных значений, характеризующих «историю» поступления запросов на передачу потоков реального времени, сформирована обучающая матрица, имеющая следующий вид:

$$\begin{pmatrix} \lambda_1 & \lambda_2 & \lambda_3 & \lambda_4 & \lambda_5 \\ \lambda_2 & \lambda_3 & \lambda_4 & \lambda_5 & \lambda_6 \\ \dots & \dots & \dots & \dots & \dots \\ \lambda_{96} & \lambda_{97} & \lambda_{98} & \lambda_{99} & \lambda_{100} \end{pmatrix}. \quad (1)$$

Для настройки весов нейронов выполнено 8 циклов обучения нечеткой нейронной сети. В результате получены выражения для функций принадлежности входных величин.

$$\mu_1(\lambda_{i-k}) = \begin{cases} 1, & \lambda_{i-k} < 0; \\ \frac{24,77 - \lambda_{i-k}}{24,77}, & 0 \leq \lambda_{i-k} < 24,77; \\ 0, & \lambda_{i-k} \geq 24,77; \end{cases} \quad (2)$$

$$\mu_2(\lambda_{i-k}) = \begin{cases} 0, & \lambda_{i-k} < 0; \\ \frac{\lambda_{i-4}}{24,77}, & 0 \leq \lambda_{i-k} < 24,77; \\ 1, & \lambda_{i-k} \geq 24,77; \end{cases} \quad (3)$$

где $k=1, 2, 3, 4$.

Кроме того, настройка нечеткой нейронной сети позволила получить значения коэффициентов индивидуальных выводов нечетких правил:

$$a_1 = -0,1558, \quad b_1 = 0,845, \quad c_1 = -1,845, \\ d_1 = 1,597, \quad e_1 = 0,926;$$

$$a_2 = 2,4435, \quad b_2 = -9,7075, \quad c_2 = 10,6225, \\ d_2 = 2,6175, \quad e_2 = -0,001;$$

$$a_3 = -11,302, \quad b_3 = 3,0425, \quad c_3 = 4,6625, \\ d_3 = -6,9975, \quad e_3 = 0,003;$$

$$a_4 = -9,555, \quad b_4 = 24,685, \quad c_4 = -12,72, \\ d_4 = 4,9375, \quad e_4 = -0,002;$$

$$a_5 = 13,872, \quad b_5 = -8,8325, \quad c_5 = 11,1075, \\ d_5 = -2,1805, \quad e_5 = -0,0085;$$

$$a_6 = -8,9575, \quad b_6 = 13,85, \quad c_6 = -21,027, \\ d_6 = 6,0675, \quad e_6 = 0,004;$$

$$a_7 = -12,285, \quad b_7 = -0,395, \quad c_7 = -8,46, \\ d_7 = 16,845, \quad e_7 = 0,003;$$

$$a_8 = 23,22, \quad b_8 = -24,385, \quad c_8 = 21,31, \\ d_8 = -16,55, \quad e_8 = 0,003;$$

$$a_9 = 0,4745, \quad b_9 = -13,207, \quad c_9 = 11,33, \\ d_9 = -12,91, \quad e_9 = 0,003;$$

$$a_{10} = -11,255, \quad b_{10} = 56,325, \quad c_{10} = -16,2525, \\ d_{10} = -0,7525, \quad e_{10} = -0,001;$$

$$a_{11} = 18,57, \quad b_{11} = -16,182, \quad c_{11} = -4,065, \\ d_{11} = -3,9825, \quad e_{11} = 0,007;$$

$$a_{12} = -0,528, \quad b_{12} = -5,595, \quad c_{12} = 6,17, \\ d_{12} = -6,1175, \quad e_{12} = -0,0105;$$

$$a_{13} = -7,005, \quad b_{13} = 20,072, \quad c_{13} = -21,755, \\ d_{13} = -3,885, \quad e_{13} = 0,008;$$

$$a_{14} = 9,6925, \quad b_{14} = -55,575, \quad c_{14} = 40,675, \\ d_{14} = 4,62, \quad e_{14} = 0,001;$$

$$a_{15} = 1,927, \quad b_{15} = 5,815, \quad c_{15} = 11,385, \\ d_{15} = -9,61, \quad e_{15} = -0,011;$$

$$a_{16} = -10,537, \quad b_{16} = 18,19, \quad c_{16} = -28,01, \\ d_{16} = 22,225, \quad e_{16} = 0,013.$$

Функционирование полученной нейро-нечеткой системы основано на использовании базы нечетких правил:

$$\text{Анїє}(\lambda_{i-4} = \alpha^1) \text{є} (\lambda_{i-3} = \beta^1) \text{є} (\lambda_{i-2} = \gamma^1) \\ \text{є} (\lambda_{i-1} = \delta^1), \text{ї} (\tilde{\lambda}_i = Y_1); \quad (4)$$

$$\text{Анїє}(\lambda_{i-4} = \alpha^1) \text{є} (\lambda_{i-3} = \beta^1) \text{є} (\lambda_{i-2} = \gamma^1) \\ \text{є} (\lambda_{i-1} = \delta^2), \text{ї} (\tilde{\lambda}_i = Y_2); \quad (5)$$

$$\text{Анїє}(\lambda_{i-4} = \alpha^1) \text{є} (\lambda_{i-3} = \beta^1) \text{є} (\lambda_{i-2} = \gamma^2) \\ \text{є} (\lambda_{i-1} = \delta^1), \text{ї} (\tilde{\lambda}_i = Y_3); \quad (6)$$

$$\text{Анїє}(\lambda_{i-4} = \alpha^1) \text{є} (\lambda_{i-3} = \beta^1) \text{є} (\lambda_{i-2} = \gamma^2) \\ \text{є} (\lambda_{i-1} = \delta^2), \text{ї} (\tilde{\lambda}_i = Y_4); \quad (7)$$

$$\text{Анїє}(\lambda_{i-4} = \alpha^1) \text{є} (\lambda_{i-3} = \beta^2) \text{є} (\lambda_{i-2} = \gamma^1) \\ \text{є} (\lambda_{i-1} = \delta^1), \text{ї} (\tilde{\lambda}_i = Y_5); \quad (8)$$

$$\text{Анїє}(\lambda_{i-4} = \alpha^1) \text{є} (\lambda_{i-3} = \beta^2) \text{є} (\lambda_{i-2} = \gamma^1) \\ \text{є} (\lambda_{i-1} = \delta^2), \text{ї} (\tilde{\lambda}_i = Y_6); \quad (9)$$

$$\text{Анїє}(\lambda_{i-4} = \alpha^1) \text{є} (\lambda_{i-3} = \beta^2) \text{є} (\lambda_{i-2} = \gamma^2) \\ \text{є} (\lambda_{i-1} = \delta^1), \text{ї} (\tilde{\lambda}_i = Y_7); \quad (10)$$

$$\text{Анїє}(\lambda_{i-4} = \alpha^1) \text{є} (\lambda_{i-3} = \beta^2) \text{є} (\lambda_{i-2} = \gamma^2) \\ \text{є} (\lambda_{i-1} = \delta^2), \text{ї} (\tilde{\lambda}_i = Y_8); \quad (11)$$

$$\text{Анїє}(\lambda_{i-4} = \alpha^2) \text{є} (\lambda_{i-3} = \beta^1) \text{є} (\lambda_{i-2} = \gamma^1) \\ \text{є} (\lambda_{i-1} = \delta^1), \text{ї} (\tilde{\lambda}_i = Y_9); \quad (12)$$

$$\text{Анїє}(\lambda_{i-4} = \alpha^2) \text{є} (\lambda_{i-3} = \beta^1) \text{є} (\lambda_{i-2} = \gamma^1) \\ \text{є} (\lambda_{i-1} = \delta^2), \text{ї} (\tilde{\lambda}_i = Y_{10}); \quad (13)$$

$$\text{Анїє}(\lambda_{i-4} = \alpha^2) \text{є} (\lambda_{i-3} = \beta^1) \text{є} (\lambda_{i-2} = \gamma^2) \\ \text{є} (\lambda_{i-1} = \delta^1), \text{ї} (\tilde{\lambda}_i = Y_{11}); \quad (14)$$

$$\begin{aligned} \text{Ãñèè} (\lambda_{i-4} = \alpha^2) \text{è} (\lambda_{i-3} = \beta^1) \text{è} (\lambda_{i-2} = \gamma^2) \\ \text{è} (\lambda_{i-1} = \delta^2), \text{õì} (\tilde{\lambda}_i = Y_{12}); \end{aligned} \quad (15)$$

$$\begin{aligned} \text{Ãñèè} (\lambda_{i-4} = \alpha^2) \text{è} (\lambda_{i-3} = \beta^2) \text{è} (\lambda_{i-2} = \gamma^1) \\ \text{è} (\lambda_{i-1} = \delta^1), \text{õì} (\tilde{\lambda}_i = Y_{13}); \end{aligned} \quad (16)$$

$$\begin{aligned} \text{Ãñèè} (\lambda_{i-4} = \alpha^2) \text{è} (\lambda_{i-3} = \beta^2) \text{è} (\lambda_{i-2} = \gamma^1) \\ \text{è} (\lambda_{i-1} = \delta^2), \text{õì} (\tilde{\lambda}_i = Y_{14}); \end{aligned} \quad (17)$$

$$\begin{aligned} \text{Ãñèè} (\lambda_{i-4} = \alpha^2) \text{è} (\lambda_{i-3} = \beta^2) \text{è} (\lambda_{i-2} = \gamma^2) \\ \text{è} (\lambda_{i-1} = \delta^1), \text{õì} (\tilde{\lambda}_i = Y_{15}); \end{aligned} \quad (18)$$

$$\begin{aligned} \text{Ãñèè} (\lambda_{i-4} = \alpha^2) \text{è} (\lambda_{i-3} = \beta^2) \text{è} (\lambda_{i-2} = \gamma^2) \\ \text{è} (\lambda_{i-1} = \delta^2), \text{õì} (\tilde{\lambda}_i = Y_{16}), \end{aligned} \quad (19)$$

где α^1 – терм номер 1 входной величины λ_{i-4} ;
 α^2 – терм номер 2 входной величины λ_{i-4} ;
 β^1 – терм номер 1 входной величины λ_{i-3} ;
 β^2 – терм номер 2 входной величины λ_{i-3} ;
 γ^1 – терм номер 1 входной величины λ_{i-2} ;
 γ^2 – терм номер 2 входной величины λ_{i-2} ;
 δ^1 – терм номер 1 входной величины λ_{i-1} ;
 δ^2 – терм номер 2 входной величины λ_{i-1} ;
 Y_r – индивидуальный вывод нечеткого правила номер r , $r = 1, 2, \dots, 16$.

$$Y_r = a_r \lambda_{i-4} + b_r \lambda_{i-3} + c_r \lambda_{i-2} + d_r \lambda_{i-1} + e_r \quad (20)$$

Нейро-нечеткая система состоит из пяти слоев. Первый слой выполняет процедуру фаззификации, которая заключается в том, что для конкретных значений входных величин λ_{i-4}^* , λ_{i-3}^* , λ_{i-2}^* и λ_{i-1}^* по формулам (2) и (3) вычисляются значения $\mu_1(\lambda_{i-k}^*)$ и $\mu_2(\lambda_{i-k}^*)$.

Вторым слоем нейро-нечеткой системы осуществляется процедура агрегирования, в процессе которой определяются степени истинности условий каждого правила при конкретных значениях входных величин:

$$\begin{aligned} G_1 = \\ = \mu_1(\lambda_{i-4}^*) \wedge \mu_1(\lambda_{i-3}^*) \wedge \mu_1(\lambda_{i-2}^*) \wedge \mu_1(\lambda_{i-1}^*); \end{aligned} \quad (21)$$

$$\begin{aligned} G_2 = \\ = \mu_1(\lambda_{i-4}^*) \wedge \mu_1(\lambda_{i-3}^*) \wedge \mu_1(\lambda_{i-2}^*) \wedge \mu_2(\lambda_{i-1}^*); \end{aligned} \quad (22)$$

$$\begin{aligned} G_3 = \\ = \mu_1(\lambda_{i-4}^*) \wedge \mu_1(\lambda_{i-3}^*) \wedge \mu_2(\lambda_{i-2}^*) \wedge \mu_1(\lambda_{i-1}^*); \end{aligned} \quad (23)$$

$$\begin{aligned} G_4 = \\ = \mu_1(\lambda_{i-4}^*) \wedge \mu_1(\lambda_{i-3}^*) \wedge \mu_2(\lambda_{i-2}^*) \wedge \mu_2(\lambda_{i-1}^*); \end{aligned} \quad (24)$$

$$\begin{aligned} G_5 = \\ = \mu_1(\lambda_{i-4}^*) \wedge \mu_2(\lambda_{i-3}^*) \wedge \mu_1(\lambda_{i-2}^*) \wedge \mu_1(\lambda_{i-1}^*); \end{aligned} \quad (25)$$

$$\begin{aligned} G_6 = \\ = \mu_1(\lambda_{i-4}^*) \wedge \mu_2(\lambda_{i-3}^*) \wedge \mu_1(\lambda_{i-2}^*) \wedge \mu_2(\lambda_{i-1}^*); \end{aligned} \quad (26)$$

$$\begin{aligned} G_7 = \\ = \mu_1(\lambda_{i-4}^*) \wedge \mu_2(\lambda_{i-3}^*) \wedge \mu_2(\lambda_{i-2}^*) \wedge \mu_1(\lambda_{i-1}^*); \end{aligned} \quad (27)$$

$$\begin{aligned} G_8 = \\ = \mu_1(\lambda_{i-4}^*) \wedge \mu_2(\lambda_{i-3}^*) \wedge \mu_2(\lambda_{i-2}^*) \wedge \mu_2(\lambda_{i-1}^*); \end{aligned} \quad (28)$$

$$\begin{aligned} G_9 = \\ = \mu_2(\lambda_{i-4}^*) \wedge \mu_1(\lambda_{i-3}^*) \wedge \mu_1(\lambda_{i-2}^*) \wedge \mu_1(\lambda_{i-1}^*); \end{aligned} \quad (29)$$

$$\begin{aligned} G_{10} = \\ = \mu_2(\lambda_{i-4}^*) \wedge \mu_1(\lambda_{i-3}^*) \wedge \mu_1(\lambda_{i-2}^*) \wedge \mu_2(\lambda_{i-1}^*); \end{aligned} \quad (30)$$

$$\begin{aligned} G_{11} = \\ = \mu_2(\lambda_{i-4}^*) \wedge \mu_1(\lambda_{i-3}^*) \wedge \mu_2(\lambda_{i-2}^*) \wedge \mu_1(\lambda_{i-1}^*); \end{aligned} \quad (31)$$

$$\begin{aligned} G_{12} = \\ = \mu_2(\lambda_{i-4}^*) \wedge \mu_1(\lambda_{i-3}^*) \wedge \mu_2(\lambda_{i-2}^*) \wedge \mu_2(\lambda_{i-1}^*); \end{aligned} \quad (32)$$

$$\begin{aligned} G_{13} = \\ = \mu_2(\lambda_{i-4}^*) \wedge \mu_2(\lambda_{i-3}^*) \wedge \mu_1(\lambda_{i-2}^*) \wedge \mu_1(\lambda_{i-1}^*); \end{aligned} \quad (33)$$

$$\begin{aligned} G_{14} = \\ = \mu_2(\lambda_{i-4}^*) \wedge \mu_2(\lambda_{i-3}^*) \wedge \mu_1(\lambda_{i-2}^*) \wedge \mu_2(\lambda_{i-1}^*); \end{aligned} \quad (34)$$

$$\begin{aligned} G_{15} = \\ = \mu_2(\lambda_{i-4}^*) \wedge \mu_2(\lambda_{i-3}^*) \wedge \mu_2(\lambda_{i-2}^*) \wedge \mu_1(\lambda_{i-1}^*); \end{aligned} \quad (35)$$

$$\begin{aligned} G_{16} = \\ = \mu_2(\lambda_{i-4}^*) \wedge \mu_2(\lambda_{i-3}^*) \wedge \mu_2(\lambda_{i-2}^*) \wedge \mu_2(\lambda_{i-1}^*). \end{aligned} \quad (36)$$

С помощью третьего слоя нейронов выполняется нормализация результатов агрегирования:

$$\bar{G}_r = G_r / \sum_{r=1}^{16} G_r, \quad (37)$$

Четвертый слой осуществляет активизацию по формуле (20) и вычисляет произведение результатов нормализации и активизации:

$$y_r = \bar{G}_r \cdot Y_r. \quad (38)$$

Процедура дефаззификации (вычисление четкого значения выходной величины) выполняется пятым слоем нейронов. При этом складываются результаты функционирования четвертого слоя системы:

$$\tilde{\lambda}_i^* = \sum_{r=1}^{16} y_r. \quad (39)$$

Синтезированная нечеткая нейронная сеть в дальнейшем может быть применена для принятия решения о передаче потоков реального времени по каналу телекоммуникационной сети. С разработанной моделью был проведен ряд имитационных экспериментов (рис. 3, 4).




Рис. 3. Інтенсивність поступлення запитів на передачу в реальній мережі




Рис. 4. Інтенсивність поступлення запитів на передачу, прогнозована за допомогою нечіткої нейронної мережі

Аналіз результатів одного з імітаційних експериментів показує, що використання нейро-нечіткої системи дозволяє отримати прийнятне якість прогнозу.

Висновки

Представлена модель нейро-нечіткого прогнозування інтенсивності надходження запитів на передачу потоків реального часу. Данна модель реалізована за допомогою п'ятишарової нечіткої нейронної мережі, функціонуючої відповідно до алгоритму Сугено 1-го порядку. Результати імітаційного моделювання показали, що застосування вказаної нечіткої нейронної мережі дозволяє отримати прийнятне якість прогнозу інтенсивності надходження запитів на передачу трафіку реального часу.

Список літератури

1. Polshchikov K. O. *Methods and technologies analysis of the real time traffic transmission requests servicing* / Polshchikov K. O., K. M. Kubrakova, Odaruschenko O.M. //

World Applied Programming, Vol. 3, N.9, September 2013, – P. – 446–450.

2. Kubrakova K. M. *Mathematical model for quality estimation of real time flows requests servicing in a telecommunication network* / K. M. Kubrakova // *Modern problems of radio engineering, telecommunications and computer science (TCSET), 12th International Conference. – Lviv, 2014. – P. 536–538.*

3. Polshchikov K. O. *Synthesis of neuro-fuzzy systems of data flows intensity control in mobile ad-hoc network* / K. O. Polshchikov // *Microwave and Telecommunication Technology (CriMiCo), 23rd International Crimean Conference. – Sevastopol, 2013. – P. 517–518.*

4. Takagi T., Sugeno M. *Fuzzy Identification of Systems and Its Applications to Modeling and Control* // *IEEE Transactions on Systems, Man and Cybernetics. – 1985. – Vol. 15, N. 1. – pp. 116 – 132.*

5. Rumelhart D.E., Hilton G.E., Williams R.J. *Learning Internal Representations by Error Propagation* // *In Parallel Distributed Processing, t. 1. – Cambridge: M.I.T. Press, 1986.*

Поступила в редколлегию 11.02.2014

Рецензент: д-р техн. наук, проф. А.Л. Ляхов, Полтавський національний технічний університет ім. Юрія Кондратюка, Полтава.

МОДЕЛЬ НЕЙРО-НЕЧІТКОГО ПРОГНОЗУВАННЯ СЕРЕДНЬОЇ ІНТЕНСИВНОСТІ НАДХОДЖЕННЯ ЗАПИТІВ НА ПЕРЕДАЧУ ПОТОКІВ РЕАЛЬНОГО ЧАСУ ПО КАНАЛУ ТЕЛЕКОМУНІКАЦІЙНОЇ МЕРЕЖІ

К.О. Польщиків, К.М. Кубракова, В.А. Краснобаєв

У статті запропонована модель прогнозування параметрів телекомунікаційної мережі, яка передбачає інтенсивність надходження запитів на передачу потоків реального часу та ґрунтується на використанні нечіткої нейронної мережі, яка функціонує у відповідності до алгоритму Сугено першого порядку.

Ключові слова: нечітка нейронна мережа, алгоритм Сугено, трафік реального часу.

NEURO FUZZY MODEL OF MEAN REAL TIME TRAFFIC REQUEST ARRIVAL INTENSITY PREDICTION IN A TELECOMMUNICATION NETWORK CHANNEL

K.A. Polshchikov, K.N. Kubrakova, V.A. Krasnobayev

This paper deals with telecommunication network parameters prediction model which allows qualitative real time traffic transmission and is based on neuro fuzzy network usage functioning according to Sugeno algorithm of the first order.

Keywords: neuro fuzzy network, Sugeno algorithm, real time traffic.