

УДК 004. 925.83

Е.Е. Федоров, д-р техн. наук, доц.,
Х.А. Аль-Абабнех, аспирант
Х. Альрабаба, аспирант
Донецкий национальный технический университет, г. Красноармейск
fedorovee75@mail.ru

Метод прогноза производительности серверных компьютерных систем

В статье изложен метод прогноза производительности серверных компьютерных систем. Предложен эффективный метод расчета факторов, влияющих на производительность. Разработан метод построения нечеткой искусственной нейронной сети. Для обучения созданной модели предложены эффективные комбинации метаэвристик на основе генетического алгоритма, алгоритма клонального отбора и имитации отжига. Для оценки прогноза созданы логико-формальные правила, использующие адаптивный нормированный порог. Предложенный метод прогноза производительности может использоваться в интеллектуальных системах анализа характеристик комплексных серверных компьютерных систем.

Ключевые слова: прогноз производительности, серверная компьютерная система, нечеткая логика, искусственная нейронная сети, метаэвристика, логико-формальные правила.

Введение

На сегодняшний день сервисно-ориентированные архитектуры и веб-услуги занимают доминирующие позиции. Это приводит к увеличению нагрузки на сервера компьютерных систем. В связи с этим актуальным является проведение исследований, направленных на разработку моделей и методов прогноза производительности для серверных компьютерных систем с целью повышения эффективности их работы.

Наиболее часто используемыми факторами, влияющими на производительности Web-серверов, являются [1-2]: время отклика при сквозной передаче данных; время отклика сайта; пропускная способность (запросов/с и Мбит/с); количество ошибок в секунду; количество посетителей в день; количество уникальных посетителей в день; коэффициент использования; выходной поток потребителей; потребность в обслуживании ресурса. Согласно работам [3-5], было установлено, что методы расчета факторов на основе имитационных моделей требуют большого объема экспериментальных данных и не дают точного решения, поэтому их использование для малых серверных компьютерных систем нецелесообразно. Существующие статистические и нейросетевые методы прогноза производительности [6-7] не дают комплексной оценки удобной для человеческого восприятия, поэтому возникает необходимость в новом методе прогноза. Существующие метаэвристические методы [8-9] не достаточно эффективны опреде-

ления параметров моделей прогноза, поэтому необходим новый метод адаптации параметров. Также возникает задача оценки качества выполненного прогноза. Для решения проблемы недостаточной эффективности прогноза производительности серверных компьютерных систем, требуется разработать метод, который базируется на методе расчета факторов, нейронечеткой модели прогноза и логико-формальных правилах оценивания прогноза.

Описание

Целью работы является разработка метода прогноза производительности серверных компьютерных систем.

Для достижения поставленной цели необходимо:

1. Разработать метод расчета факторов, влияющих на производительность.
2. Создать модель прогноза производительности на основе нечеткой логики и искусственной нейронной сети.
3. Разработать критерий оценки эффективности модели прогноза.
4. Создать метод определения параметров модели прогноза.
5. Разработать логико-формальные правила для оценивания результатов прогноза по модели

2. Метод расчета факторов, влияющих на производительность

Для повышения эффективности прогноза в статье предложен новый метод расчета факторов, который имеет структуру, представленную на рис.1.

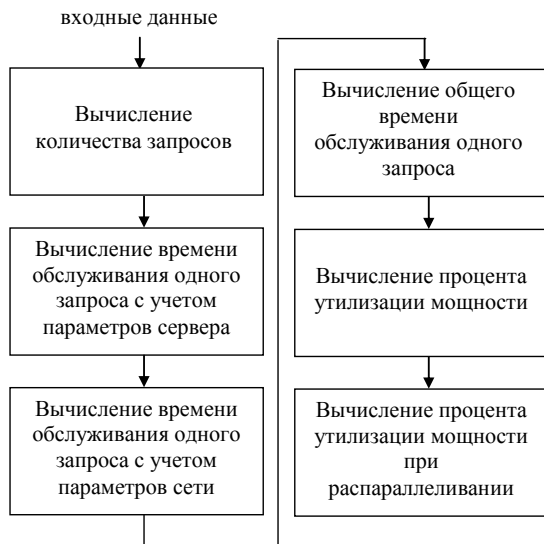


Рисунок 1 – Структура расчета факторов, влияющих на производительность

Первый фактор – количество запросов

$$K = k_{time} K_{base}, \quad (1)$$

где K_{base} – интенсивность поступления запросов, запрос/сек;

k_{time} – коэффициент обработки запросов, показывающий распределение всех поступивших запросов на ресурс по отношению к отдельно взятому контенту или функции, выполняемой на веб-странице:

На k_{time} наложены следующие ограничения

$$k_{time} = \{k_i | 0 \leq k_i \leq 1\},$$

$$\sum_{i=1}^n k_i = 1,$$

где n – количество типов запросов.

Второй фактор – время обслуживания одного запроса с учетом параметров сервера

$$T_s = \frac{N_s}{W_s}, \quad (2)$$

где T_s – время обслуживания одного запроса для сервера типа S, сек

N_s – нагрузка на сервер, количество операций (инструкций);

W_s – производительность сервера, операций (инструкций)/сек

Третий фактор – время обслуживания одного запроса с учетом параметров сети

$$T_L = \frac{D_L}{C_L}, \quad (3)$$

где T_L – время обслуживания одного запроса, при передаче по сети типа L, сек;

D_L – объем передаваемых данных, бит;

C_L – производительность сети типа L, бит/сек.

Четвертый фактор – общее время обслуживания одного запроса

$$T = \sum_{i=1}^n t_{F_i} = \sum_{i=1}^n \left(\sum_{k=1}^S (T_{sik}^{CPU} + T_{sik}^{IO}) + \sum_{j=1}^L T_{Lij} \right), \quad (4)$$

где n – количество типов запросов,

t_{F_i} – общее время обслуживания запроса

i -го типа,

L – количество сетей, участвующих в передаче запроса;

S – количество серверов, участвующих в обработке запроса.

Пятый фактор – процент утилизации мощности

Для сервера типа S

$$P_{WS} = \sum_{i=1}^n \left(\frac{K_i}{10^3} \cdot \frac{T_{si}}{3600} \right) \cdot 100\%, \quad (5)$$

где n – количество типов запросов.

Для сети типа L

$$P_{WL} = \sum_{i=1}^n \left(\frac{K_i}{10^3} \cdot \frac{T_{Li}}{3600} \right) \cdot 100\%, \quad (6)$$

Шестой фактор – процент утилизации мощности при распараллеливании

Для сервера типа S

$$P_{WS}^{\parallel} = \frac{P_{WS}}{n \cdot k_{\parallel}}, \quad (7)$$

где n – количество параллельных компьютеров;

k_{\parallel} -- коэффициент эффективности распараллеливания.

Для сети типа L

$$P_{WL}^{\parallel} = \frac{P_{WL}}{n \cdot k_{\parallel}}, \quad (8)$$

2. Метод построения модели комплексного прогноза производительности

Метод построения модели комплексного прогноза производительности включает в себя:

- формирование базы нечетких правил;
- создание структуры модели;
- разработку процедуры прогноза по мо-

- дели;
- создание критериев оценки эффективности модели;
- адаптация параметров модели.

2.1. Формирование базы нечетких правил

Используемые при построении модели нечеткой нейросети нечеткие правила имеют вид
ПРАВИЛО k : ЕСЛИ *условие* k

ТО *заключение* k (F^k), (9)

где k – номер правила,

F^k – коэффициент определенности, коэффициент уверенности или весовой коэффициент нечеткого правила (принимает значение из интервала $[0,1]$), $k \in \overline{1, r}$,

условие k – это совокупность подусловий вида

\tilde{x}_1 есть $\tilde{\alpha}_1^k$ И ... И \tilde{x}_n есть $\tilde{\alpha}_n^k$,

заключение k – это заключение вида

\tilde{y} есть $\tilde{\beta}^k$,

\tilde{x}_i – имя входной лингвистической переменной, соответствующей фактору, $i \in \overline{1, n}$,

\tilde{y} – имя выходной лингвистической переменной, соответствующей комплексному прогнозу,

$\tilde{\alpha}_i^k$ – качественное значение переменной \tilde{x}_i , $k \in \overline{1, r}$, $i \in \overline{1, n}$,

$\tilde{\beta}^k$ – качественное значение переменной

\tilde{y} , $k \in \overline{1, r}$.

2.2. Создание структуры модели

Для комплексного прогноза производительности предложена модель четырехслойной нечеткой нейросети. Пример структуры модели нечеткой нейросети в случае двух входных переменных, каждая из которых связана с тремя качественными оценками, и трех выходных переменных (соответствуют качественным оценкам комплексного прогноза) представлен на рис. 2.

Модель нечеткой нейросети для прогноза комплексной производительности формируется по следующему принципу. Входной (нулевой) слой содержит нейроны, которые соответствуют предложенным факторам, количество нейронов $N^{(0)} = n$. Первый слой реализует фаззификацию, а его нейроны соответствуют качественным значениям факторов, количество нейронов

$$N^{(1)} = \sum_{i=1}^n n_i, \text{ где } n_i \text{ – количество качественных}$$

значений для i -й входной лингвистической переменной.




Рисунок 2 – Структура модели нечеткой нейросети

Второй слой реализует агрегирование подусловий, а его нейроны соответствуют условиям, количество нейронов $N^{(2)} = \prod_{i=1}^n n_i = r$, где r –

количество нечетких правил. Третий слой реализует активизацию правил, а его нейроны соответствуют заключениям, количество нейронов

$$N^{(3)} = \prod_{i=1}^n n_i = r.$$

Четвертый (выходной) слой реализует агрегирование заключений, а его нейроны соответствуют качественным значениям комплексного прогноза, количество нейронов $N^{(4)} = q$, где q – количество качественных значений выходной лингвистической переменной

2.3. Разработка процедуры комплексного прогноза по модели

Процедура комплексного прогноза по модели включает 4 этапа: фаззификация; агрегирование подусловий; активизация заключений; агрегирование заключений.

2.3.1. Фаззификация

Фаззификация (введение нечеткости) представляет собой процедуру определения степени истинности подусловий нечетких правил.

Целью фаззификации является установление соответствия между значением входной четкой переменной (фактором) x_i и значением функции принадлежности соответствующего ей качественного значения $\tilde{\alpha}_i^v$, в виде

$$y_s^{(1)} = \mu_{\tilde{\alpha}_i^v}(x_i), \text{ } s \in \overline{1, N^{(1)}}, \text{ } i \in \overline{1, N^{(0)}}, \text{ } (10)$$

$$v = s - \sum_{z=1}^{i-1} n_z,$$

где $\mu_{\tilde{A}_i^v}$ – функции принадлежности нечеткого множества \tilde{A}_i^v , которое определяет область значений $\tilde{\alpha}_i^v$,

x_i – четкая входная переменная (фактор),
 $y_s^{(1)}$ – степень истинности i -го подусловия « \tilde{x}_i есть $\tilde{\alpha}_i^v$ ».

В качестве функции принадлежности в работе была выбрана функция Гаусса

$$y_s^{(1)} = \mu_{\tilde{A}_i^v}(x_i) = \exp\left(-\frac{(x_i - m_i^v)^2}{2(\sigma_i^v)^2}\right), \quad (11)$$

где m_i^v , σ_i^v – математическое ожидание и среднеквадратичное отклонение для численного значения i -го фактора, связанного с v -м качественным значением.

2.3.2. Агрегирование подусловий

Агрегирование подусловий нечеткого правила представляет собой процедуру определения степени истинности условия этого правила по степеням истинности составляющих его подусловий.

Для агрегирования подусловий в работе был выбран метод минимального значения

$$y_k^{(2)} = \min_{s \in 1, N^{(1)}} w_{sk}^{(2)} y_k^{(1)}, \quad k \in 1, N^{(1)}, \quad (12)$$

где $w_{sk}^{(2)}$ – бинарный вес связи, который определяется структурой модели

Функция активации берется линейной, т.е.

$$f^{(2)}(x) = x.$$

2.3.3. Активизация заключений

В данной работе активизация заключения нечеткого правила представляет собой процедуру определения степени истинности заключения этого правила по степени истинности его условия и его весовому коэффициенту.

Для активизации заключений в работе было выбрано

$$y_k^{(3)} = w_{kk}^{(3)} y_k^{(2)}, \quad k \in 1, N^{(2)}, \quad (13)$$

где $w_{kk}^{(3)}$ – вес связи, соответствующий весовому коэффициенту нечеткого правила F^k (принимает значение из интервала $[0,1]$), вычисляется экспериментально.

Функция активации берется линейной, т.е.

$$f^{(3)}(x) = x.$$

2.3.4. Агрегирование заключений

Агрегирование заключений представляет собой процедуру объединения степени истинности одинаковых заключений для получения степени истинности итогового заключения.

Для агрегирования заключений в работе был выбран метод максимального значения

$$y_j = \max_{s \in 1, N^{(3)}} w_{kj}^{(4)} y_k^{(3)}, \quad j \in 1, N^{(4)}, k \in 1, N^{(3)}, \quad (14)$$

где $w_{kj}^{(4)}$ – бинарный вес связи, который определяется структурой модели.

Функция активации берется линейной, т.е.

$$f^{(4)}(x) = x.$$

2.4. Критерий оценки эффективности модели

В работе выбран критерий адекватности модели, который означает выбор таких значений параметров функций принадлежности, которые доставляют минимум среднеквадратичной ошибки (разности выхода по модели и желаемого выхода)

$$F = \frac{1}{P} \sum_{p=1}^P \sum_{j=1}^q (y_{pj} - d_{pj})^2 \rightarrow \min_{m_i^v, \sigma_i^v}, \quad (15)$$

где P – количество тестовых реализаций,

$y_p = (y_{p1}, \dots, y_{pq})$ – оценка производительности, полученная по модели,

$d_p = (d_{p1}, \dots, d_{pq})$ – желаемая оценка производительности.

2.5. Адаптация параметров модели комплексного прогноза производительности

В данной статье получили дальнейшее развитие идеи, предложенные в работе [10].

В статье используется алгоритм клонального отбора с имитацией отжига, который включает в себя следующие блоки:

- создание исходной популяции (антитело состоит из параметров функций Гаусса);
- задание функция цели (15);
- вычисление аффинности;
- оператор клонирования в комбинации с имитацией отжига;
- оператор мутации;
- добавление новых антител в комбинации с имитацией отжига;
- оператор редукции в комбинации с имитацией отжига;
- условие останова.

В статье также предлагается генетический алгоритм с имитацией отжига, который включает в себя следующие блоки:

- создание исходной популяции (хромосома состоит из параметров функций Гаусса);
- задание фитнес-функция (15);
- оператор репродукции (селекции) в комбинации с имитацией отжига;
- оператор кроссинговера (кроссовера, рекомбинации) в комбинации с имитацией отжига;
- оператор мутации в комбинации с имитацией отжига;
- оператор редукции в комбинации с имитацией отжига;
- условие останова.

3. Формирования логико-формальных правил оценивания комплексного прогноза производительности

Для оценивания результатов комплексного прогноза производительности формируются следующие логико-формальные правила

$$\max_{j \in 1, q} y_j > \varepsilon \rightarrow v = 1, \tag{16}$$

$$\max_{j \in 1, q} y_j \leq \varepsilon \rightarrow v = 0, \tag{17}$$

где v – логический признак правильности прогноза.

Адаптивный нормированный порог для логико-формальных правил (16) и (17) минимизирует вероятность ошибки прогноза и оценивается в виде

$$\frac{1}{M} \sum_{p=1}^M I(\arg \max_{j \in 1, q} y_{pj}, \arg \max_{j \in 1, q} d_{pj}) = 0 \rightarrow \tag{18}$$

$$\rightarrow \varepsilon = \max_{p \in 1, M, j \in 1, q} y_{pj}$$

$$I(a, b) = \begin{cases} 1, & a = b \\ 0, & a \neq b \end{cases}, \tag{19}$$

где M – количество неправильно выполненных прогнозов.

4. Численное исследование методов комплексного прогноза производительности

Для численного исследования алгоритма клонального отбора в работе было выбрано два основных типа (табл. 1).

Первый тип исследует все пространство поиска и не является направленным. Для этого типа возможна потеря лучших решений. Он требует значительного времени поиска. Второй тип, описанный в 2.5, является комбинированным, т.е. совмещает направленность поиска с исследованием всего пространства поиска.

Таблица 1 - Структура алгоритмов клонального отбора двух типов

| Операторы алгоритмов клонального отбора | Типы алгоритмов клонального отбора | |
|---|------------------------------------|----------------------|
| | Тип 1 | Тип 2 (предложенный) |
| Клонирование | без имитации отжига | с имитацией отжига |
| Мутация | обычная | обычная |
| Добавление новых антител | без имитации отжига | с имитацией отжига |
| Редукция | без имитации отжига | с имитацией отжига |

Результаты численного исследования методов прогноза с объемом выборки 400 представлены в табл. 2, при этом для адаптации параметров модели использовались алгоритмы клонального отбора двух типов. Согласно табл. 2, использование алгоритма типа 2 является наиболее эффективным для проведения прогноза.

Таблица 2 - Результаты численного исследования типов алгоритмов клонального отбора, используемых при прогнозе производительности, по двум критериям

| Способ расчета факторов | Оценка скорости обучения (количества итераций) для алгоритма клонального отбора | | Оценка адекватности (среднеквадратичной ошибки) для алгоритма клонального отбора | |
|-------------------------|---|-------|--|-------|
| | тип 1 | тип 2 | тип 1 | тип 2 |
| типичный | 150 | 125 | 0.08 | 0.06 |
| предложенный | 130 | 110 | 0.06 | 0.02 |

Для численного исследования генетического алгоритма в работе было выбрано два основных типа (табл. 3). Первый тип исследует все пространство поиска и не является направленным. Для этого типа возможна потеря лучших решений. Он требует значительного времени поиска. Второй тип, описанный в 2.5, является комбинированным, т.е. совмещает направленность поиска с исследованием всего пространства поиска.

Результаты численного исследования методов прогноза с объемом выборки 400 представлены в табл. 4, при этом для адаптации параметров модели использовались генетические алгоритмы трех типов. Согласно табл. 4, использование алгоритма типа 3 является наиболее эффективным для проведения прогноза.

Таблица 3 - Структура генетических алгоритмов
трех типов

| Операторы генетических алгоритмов | Типы генетических алгоритмов | | |
|-----------------------------------|---|--|--|
| | Тип 1 | Тип 2 | Тип 3 (предложенный) |
| Репродукция | равновероятный отбор | пропорциональный отбор | комбинация равновероятного и пропорционального отбора |
| Кроссинговер | равновероятный, отбор особей – аутбридинг | равновероятный, отбор особей – инбридинг | равновероятный, отбор особей – комбинация аутбридинга и инбридинга |
| Мутация | однородная с высокой вероятностью | однородная с низкой вероятностью | неоднородная |
| Редукция | равновероятная схема | селекционная схема | комбинация равновероятной и селекционной схемы |

Таблица 4 - Результаты численного исследования типов генетического алгоритмов, используемых при прогнозе производительности, по двум критериям

| Способ расчета факторов | Оценка скорости обучения (количества итераций) для генетического алгоритма | | | Оценка адекватности (среднеквадратичной ошибки) для генетического алгоритма | | |
|-------------------------|--|------|------|---|------|------|
| | тип1 | тип2 | тип3 | тип1 | тип2 | тип3 |
| типичный | 200 | 140 | 115 | 0.07 | 0.07 | 0.05 |
| предложенный | 150 | 120 | 100 | 0.05 | 0.05 | 0.01 |

Как видно из табл. 2 и 4, генетический алгоритм типа 3 с предложенным способом расчета факторов дает более высокие результаты, чем алгоритмы клонального отбора.

Заклучение

В работе усовершенствован метод прогноза производительности серверных компьютерных систем, который отличается тем, что использует предложенный метод расчета факторов, разработанная нейронечеткую модель и логико-формальные правила оценивания с адаптивным нормированным порогом, что позволяет уменьшить вероятность неправильного прогноза. Получили дальнейшее развитие методы расчета характеристик серверных компьютерных систем, которые позволяют повысить точность прогноза производительности. Впервые создана нечеткая нейросетевая модель прогноза производительности серверных компьютерных систем, которая отличается тем, что, используя формализацию знаний в виде нечетких правил, позволяет анализировать систему факторов и дает комплексную оценку производительности, что упрощает взаимодействие человека с компьютерной системой. Усовершенствован метод определения параметров предложенной нейронечеткой модели, который в отличие от существующих основан на эффективной комбинации метаэвристик, что позволяет увеличить адекватность моделей и скорость их обучения.

Созданные методы могут использоваться в интеллектуальных системах для решения задач, связанных с анализом характеристик серверных компьютерных систем.

Список использованной литературы

1. Менаске Д. Производительность Web-служб. Анализ, оценка и планирование / Д. Менаске, В. Алмейда. – СПб: ООО «ДиаСофтЮП», 2003. – 480 с.
2. Menasce D.A. Capacity Planning and Performance Modeling. From Mainframes to Client-Server Systems / D.A. Menasce, A.F. Almeida, and L.W. Dowdy. – Prentice Hall, Upper Saddle River, New Jersey. – 1994.
3. Тематический обзор по областям исследований научной специальности ВАК России 08.00.13 «Математические и инструментальные методы экономики» / О.В. Голосов, И.Н. Дрогобыцкий, Б.И. Герасимов, В.Н. Дякин. – Тамбов: Изд-во Тамб. гос. техн. ун-та, 2004. – 236 с.
4. Емельянов А.А. Имитационное моделирование экономических процессов: учеб. пособие / А.А. Емельянов, Е.А. Власова, Р.В. Дума. – М.: Финансы и статистика, 2002. – 368 с.
5. Мур Дж. Экономическое моделирование в Microsoft Excel / Дж. Мур, Л.Р. Уэдерфорд. – М.: Издательский дом «Вильямс», 2004. – 1024 с.
6. Громова Н.М. Основы экономического прогнозирования: учеб. пособие / Н.М. Громова, Н.И. Громова. – М.: Издательство Академия Естествознания, 2006. – 457 с.
7. Лапыгин Ю.Н. Экономическое прогнозирование / Ю.Н. Лапыгин, В.Е. Крылов, А.П. Чернявский. – М.: Эксмо, 2009. – 256 с.
8. Brownlee J. Clever Algorithms: Nature-Inspired Programming Recipes / J. Brownlee. – Melbourne: Brownlee, 2011. – 436 p.

9. Скобцов Ю.А. Метаэвристики / Ю.А. Скобцов, Е.Е. Федоров. – Донецк: Изд-во «Ноулідж» (Донецкое отделение), 2013. – 426 с.
10. Федоров Е.Е. Усовершенствование метаэвристических методов для решения задачи поиска оптимального маршрута / Е.Е. Федоров, О.П. Мартынова, Э. Слесорайтите // Наукові праці Донецького національного технічного університету. – 2013. – №1. – С. 117-124.

Надійшла до редакції 19.01.2015

Є.Є. ФЕДОРОВ, Х.А. АЛЬ-АБАБНЕХ, Х. АЛЬРАБАБА

Донецький національний технічний університет, м. Красноармійськ

МЕТОД ПРОГНОЗУ ПРОДУКТИВНОСТІ СЕРВЕРНИХ КОМП'ЮТЕРНИХ СИСТЕМ

У статті викладено метод прогнозу продуктивності серверних комп'ютерних систем. Запропоновано ефективні фактори, що впливають на продуктивність, і метод їх розрахунку. Розроблено метод побудови нечіткої штучної нейронної мережі. Для навчання створеної моделі запропоновані ефективні комбінації метаевристик на основі генетичного алгоритму, алгоритму клонального відбору та імітації відпаду. Для оцінки прогнозу створені логіко-формальні правила, що використовують адаптивний нормований поріг. Запропонований метод прогнозу продуктивності може використовуватися в інтелектуальних системах аналізу характеристик комплексних серверних комп'ютерних систем.

Ключові слова: *прогноз продуктивності, серверна комп'ютерна система, нечітка логіка, штучна нейронна мережа, метаевристика, логіко-формальні правила.*

Ye. FEDOROV, H.A. AL-ABABNEH, H. ALRABABAH

Donetsk National Technical University, Krasnoarmiysk

METHOD FOR PREDICTING THE PERFORMANCE OF SERVER COMPUTER SYSTEMS

To date, the service-oriented architecture and Web services occupy a dominant position. This increases the load on the server computer systems. In this regard, current research is aimed at developing models and methods of forecasting performance for server computer systems to improve the efficiency of their work. Existing statistical and neural network forecasting methods do not provide a comprehensive performance evaluation convenient for human perception, so there is a need for a new method of prediction. Existing metaheuristic methods are not sufficiently effective for determination of the parameters of the forecast models, therefore, a new method of adaptation options. Also, there is the problem of estimating the quality of performance prediction. To solve the problem of insufficient effectiveness of the forecast a method for forecasting the performance of server computer systems is presented in the article. The authors modified the classic algorithm of Mamdani fuzzy inference for fuzzy forecasting, wherein the step of defuzzification is excluded. As the membership functions Gaussian function was used. In this paper we improved the method for predicting the performance of server computer systems, which are characterized in that the proposed methods for calculating the factors, developed neuro-fuzzy model and logical-formal rules of evaluation with normalized adaptive threshold, which reduces the probability of a wrong forecast. The methods were further developed for calculating the characteristics of server computer systems (the number of requests, the time to process a request with the server settings, the time to process a request within the parameters of the network, the total time to process a request, the percentage of utilization of capacity server and network capacity utilization rate for thread for the server and network), which improves the accuracy of the prediction performance. A fuzzy neural network model for prediction of performance of server computer systems was first created, which is characterized in that, using the formalization of knowledge in the form of fuzzy rules, the system allows you to analyze the factors and provides a comprehensive assessment of the performance, which simplifies human interaction with a computer system. An improved method for determining the parameters of the proposed neuro-fuzzy model is based on the effective combination of metaheuristics (genetic algorithm and clonal selection algorithm with simulated annealing), thus increasing the adequacy of the models and their rate of learning.

Keywords: *forecast performance, server computer system, fuzzy logic, artificial neural network, metaheuristics, logical-formal rules.*