

ИННОВАЦИОННЫЕ ОБРАЗОВАТЕЛЬНЫЕ ТЕХНОЛОГИИ

УДК 519.6

ИНТЕЛЛЕКТУАЛИЗАЦИЯ ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ В ЗАДАЧАХ ОПТИМИЗАЦИИ СЛОЖНЫХ ТЕХНИЧЕСКИХ СИСТЕМ НА ОСНОВЕ НЕЙРО-НЕЧЕТКИХ СЕТЕЙ ANFIS

А. С. КАБИЛЬДЖАНОВ, Э. О. БОЗОРОВ, Ч. З. ОХУНБОБОЕВА

Национальный исследовательский университет

«Ташкентский институт инженеров ирригации и механизации сельского хозяйства»,
г. Ташкент, Республика Узбекистан, e-mail: kabiljanov@yandex.ru, e.bozorov@tiiae.uz, ch.ohunboboeva@tiiae.uz

(Поступила в редакцию 13.06.2023)

Рассмотрены основные проблемы, возникающие при решении задач многокритериальной оптимизации параметров сложных технических систем.

Предлагается схема скаляризации векторных критериев оптимальности, основанная на комплексном применении методов максиминной и среднестепенной сверток, которая позволяет получить гладкий критерий оптимальности и обойти негативный эффект «заклинивания». Разработанный глобальный критерий оптимальности направлен на максимизацию запаса, с которым выполняются функциональные ограничения на выходные параметры технической системы, который позволяет преодолеть проблему «овражности» и получить единственное решение, используя при этом простейшие алгоритмы гладкой оптимизации.

Предложен интеллектуальный алгоритм поддержки принятия решений в задачах многокритериальной оптимизации параметров сложных технических систем в условиях «неопределенности приоритетов», которая выражается в неопределенности весовых коэффициентов по выходным параметрам технической системы. Основу алгоритма составляют процедуры максимизации функции предпочтений лица, принимающего решение, и ее аппроксимации нейро-нечеткой сетью ANFIS. Рассмотрен пример реализации предложенной методики решения задачи многокритериальной оптимизации параметров сложных технических систем применительно к установке электро-импульсной обработки корневой системы томатов.

Ключевые слова: многокритериальная оптимизация, математическая модель, векторный критерий, скаляризация, поддержка принятия решения, функция предпочтений, аппроксимация, ANFIS, томаты, корневая система, электро-импульсная обработка.

The main problems that arise in solving problems of multicriteria optimization of the parameters of complex technical systems are considered.

A scalarization scheme for vector optimality criteria is proposed, based on the complex application of the methods of maximin and average power convolutions, which allows obtaining a smooth optimality criterion and bypassing the negative effect of "jamming". The developed global optimality criterion is aimed at maximizing the margin with which the functional restrictions on the output parameters of the technical system are met, allows overcoming the "ravine" problem and obtaining a unique solution using the simplest smooth optimization algorithms.

An intellectual decision support algorithm is proposed in the problems of multicriteria optimization of the parameters of complex technical systems under the conditions of "uncertainty of priorities", which is expressed in the uncertainty of weight coefficients for the output parameters of the technical system. The basis of the algorithm is the procedure for maximizing the decision maker's preference function and its approximation by the neuro-fuzzy network ANFIS. An example of the implementation of the proposed methodology for solving the problem of multi-criteria optimization of the parameters of complex technical systems in relation to the installation of electric-pulse processing of the root system of tomatoes is considered.

Key words: multicriteria optimization, mathematical model, vector criterion, scalarization, decision support, preference function, approximation, ANFIS, tomatoes, root system, electro-pulse processing.

Введение

Одной из главных особенностей задачи параметрической оптимизации сложных технических систем является ее многокритериальность. На практике при решении многокритериальных оптимационных задач возникает две проблемы. Первая проблема заключается в том, что большинство традиционных методов скаляризации векторных критериев оптимальности дают модифицированный критерий оптимальности, который не является гладким. В этих условиях обычные численные методы оптимизации, ориентированные на гладкие критерии оптимальности, оказываются неэффективными из-за так называемого эффекта «заклинивания». Вторая проблема заключается в том, что большин-

ство методов скаляризации векторных критериев оптимальности, таких как, например, методы свертки, требуют задания приоритетов (весовых коэффициентов) по каждому частному критерию оптимальности. На практике задание приоритетов не является тривиальной задачей и создает ситуацию неопределенности.

Основное направление для преодоления первой проблемы лежит в плоскости решения некорректных задач, для которых разработаны методы регуляризации [1]. Практическая реализация этих методов встречает ряд трудностей, из-за необходимости проведения дополнительного функционального анализа, что связано с большими вычислительными затратами. Решение второй проблемы возможно введение функции предпочтений (ФП) лица, принимающего решение (ЛПР), с последующей ее аппроксимацией использованием различных методов теории методов искусственного интеллекта. Наиболее эффективными такими методами являются нечеткие и нейросетевые методы аппроксимации [2, 3].

Основная часть

Постановка задачи. Математическая модель сложной технической системы (СТС) имеет следующий вид:

$$y_i = f_i(x, a); \quad i = \overline{1, k}, \quad (1)$$

где $y_i; i = \overline{1, k}$ выходные параметры СТС, играющие роль частных критериев оптимальности; $x = (x_1, x_2, \dots, x_n)$ – вектор режимно-конструктивных параметров СТС; $f_i; i = \overline{1, k}$ – заданные функции; a – параметры математической модели СТС, значения которых заранее известны.

Как правило, при параметрической оптимизации СТС на ее параметры накладываются следующие ограничения:

- 1) $y_i \leq t_i; y_j = t_j; y_l \geq t_l$ – функциональные ограничения на выходные параметры, определяющие условия работоспособности СТС;
- 2) $x_{j \min} \leq x_j \leq x_{j \max}; j = \overline{1, n}$ – прямые ограничения на режимно-конструктивные параметры СТС.

Переписав функциональные ограничения на выходные параметры СТС в виде $g(x) \leq 0$, общую детерминированную задачу принятия решения по выбору вектора внутренних параметров при оптимальном параметрическом синтезе СТС можно формализовать следующим образом:

$$f_i(x, a) \stackrel{\textcircled{R}}{=} \min_{x \in \Omega_x} ; (i = \overline{1, k}), \quad (2)$$

где $\Omega_x = \left\{ x \in R^n \mid g_i(x) \leq 0; i = \overline{1, k}; x_{j \min} \leq x_j \leq x_{j \max}; j = \overline{1, n} \right\}$ – множество допустимых решений.

Предположение того, что каждый из выходных параметров в выражении (2) необходимо минимизировать, не ограничивает общности постановки задачи параметрической оптимизации СТС, поскольку функциональные ограничения $y_i \leq t_i$ можно заменить на противоположные $y_i \geq t_i$ путем введения обратных функций, либо умножением обеих частей неравенства на -1.

Метод решения. Оптимационная задача (2) не является стандартной в силу наличия векторного критерия оптимальности. Произведем редукцию исходной задачи с векторным критерием оптимальности (2) к однокритериальной оптимационной задаче на основе комбинации методов максиминной и среднестепенной сверток [4]. Окончательно получим скалярный критерий оптимальности вида:

$$F(x) = \sum_{i=1}^k \exp[-\gamma \cdot \varphi_i(x, a)] \rightarrow \min_{x \in D}; \quad \gamma = 1, 2, \dots \quad (3)$$

где D – множество допустимых решений, задаваемое функциональными ограничениями на внутренние параметры; $\varphi_i(x, a) = \alpha_i [(t_i - f_i(x, a)) / \delta_i - 1] \geq 0$ – запас, являющийся оценкой степени выполнения функциональных ограничений на выходные параметры СТС $y_i \leq t_i, i = \overline{1, k}$; δ_i – оценка расстояния i -го выходного параметра; α_i – весовые коэффициенты, определяющие относительную значимость отдельных выходных параметров СТС: $\alpha_i > 0; (\sum_{i=1}^k \alpha_i = 1); \gamma = 1, 2, \dots$ – целое число, используемое для управления сходимостью процедуры оптимизации.

Функциональные ограничения на управляющие параметры в множестве D могут быть получены из прямых ограничений на эти же параметры в множестве W_x с помощью соответствующих формул замены [5]. Например, может быть использована формула $x_j = x_{j\max} + (x_{j\min} - x_{j\max}) * \sin^2(x_j)$, где x_j – значение j -го варьируемого параметра из множества Ω_x .

Применение на практике модифицированного критерия (3) позволяет не только осуществить скаляризацию векторного критерия оптимальности, но и преодолеть проблему «овражности» и в силу ограниченности и замкнутости множества D получить единственное решение, используя при этом простейшие алгоритмы гладкой оптимизации [6].

Основная проблема при решении задачи (3) заключается в том, что значения α_i , $i = \overline{1, k}$ могут быть заранее неизвестны, что приводит к неопределенности приоритетов. В этом случае общая постановка многокритериальной оптимизационной задачи (2) может быть сформулирована следующим образом. Пусть задана векторная функция $\Psi(x, a) = (f_1(x, a), f_2(x, a), \dots, f_k(x, a))$, компонентами которой являются частные критерии оптимальности и, которая определена на множестве альтернатив W_x вектора варьируемых параметров x . Необходимо найти такое решение на множестве W_x , которое минимизировало бы все компоненты вектор-функции $\Psi(x, a)$.

При каждом фиксированном векторе $A = (\alpha_1, \alpha_2, \dots, \alpha_k)$, свертки сводят решение задачи (3) к решению однокритериальной оптимизационной задачи вида:

$$\min_{x \in D} F(x, A) = F(x^*, A), \quad (4)$$

решение которой, как было показано выше, существует.

Обозначим множество достижимости задачи (множество, в которое векторный критерий оптимальности отображает множество W_x) как Ω_Ψ ; фронт Парето задачи – Ω_Ψ^* , $\Omega_\Psi^* \subset \Omega_\Psi$; множество Парето – Ω_x^* . Если $x \in \Omega_x^*$, то будем считать, что вектор x – эффективный по Парето вектор [7].

Если при каждом $A \in D_A = \{A | \alpha_i \leq 0, \sum_{i=1}^k \alpha_i = 1\}$ решение задачи (4) единственно, то это означает, что каждому из допустимых векторов A соответствует единственный вектор x^* и соответствующие значения частных критериев оптимальности $f_1(x, a), f_2(x, a), \dots, f_k(x, a)$. Исходя из этого, можно построить некоторую функцию предпочтения $\zeta(A)$ лица, принимающего решение, определенную на множестве $D_A : \zeta : A \rightarrow R$. Тогда задача многокритериальной оптимизации сводится к выбору такого $A^* \in D_A$, при котором $\max_{A \in D_A} \zeta(A) = \zeta(A^*)$.

Будем считать, что ζ является лингвистической переменной, принимающей $e = 5$ конечных значений: «Very bad», «Bad», ..., «Very Well». Ядро нечеткой переменной ζ обозначим ζ^0 [8] и введем следующее соответствие: значению ζ «Very bad» соответствует $\zeta^0 = 1$, значению ζ «bad» соответствует $\zeta^0 = 2$, значению ζ «Average» соответствует $\zeta^0 = 3$, значению ζ «Well» соответствует $\zeta^0 = 4$ и значению ζ «Very Well» соответствует $\zeta^0 = 5$.

Таким образом, задача многокритериальной оптимизации сводится к отысканию вектора $A^* \in D_A$, обеспечивающего максимум дискретной функции $\zeta(A)$:

$$\max_{A \in D_A} \zeta(A) = \zeta(A^*), \quad (5)$$

т.е. к аппроксимации функции предпочтения лица, принимающего решение.

Общая схема решения такой задачи носит итерационный характер и имеет несколько этапов [9].

На первом этапе случайным или каким-либо другим образом генерируется n векторов A_1, A_2, \dots, A_m . Порядок следующих действий сводится к следующему.

1) Решается однокритериальная задача:

$$\min_{x \in D} F(x, A_l) = F(x^*, A_l), \quad l = \overline{1, m}. \quad (6)$$

- 2) Выводятся найденные значения $x_l^*; l = \overline{1, m}; f_i(x_l^*); i = \overline{1, k}$.
- 3) Оцениваются полученные значения $f_i(x_l^*); i = \overline{1, k}; l = \overline{1, m}$ и вводятся значения функции предпочтения $z(A_l); l = \overline{1, m}$.

На втором этапе на основе значений A_1, A_2, \dots, A_m и оценок $z(A_l); l = \overline{1, m}$ выполняются следующие действия:

- 1) Строится функция $\tilde{\zeta}_1(A)$ аппроксимирующая $\zeta(A)$ в окрестности точек A_1, A_2, \dots, A_m ;
- 2) Решается однокритериальная задача

$$\max_{A \in D_A} \tilde{\zeta}_1(A) = \tilde{\zeta}(A_1^*); \quad (7)$$

- 3) Решается однокритериальная задача $\min_{x \in OD} F(x, A_1^*) = F(x^*, A_1^*)$;

- 4) Выводятся найденные значения $x^*; f_i(x^*); i = \overline{1, k}$;

- 5) Оцениваются полученные значения $f_i(x^*); i = \overline{1, k}$ и вводится значение функции предпочтения $\zeta(A_1^*)$.

На третьем этапе на основе имеющихся значений $A_1, A_2, \dots, A_m, A_1^*$ и соответствующих оценок функции предпочтения $\zeta(A_1), \zeta(A_2), \dots, \zeta(A_k), \zeta(A_1^*)$ выполняется аппроксимация функции $\zeta(A)$ в окрестности точек $A_1, A_2, \dots, A_m, A_1^*$, в результате которой строится функция $\tilde{\zeta}_2(A)$.

Далее процедура продолжается по схеме второго этапа до тех пор, пока лицом, принимающим решение, не будет принято решение о прекращении вычислений. На каждой итерации допускается «откат» с целью изменения введенных ранее оценок своей функции предпочтения.

При использовании аддитивной нейро-нечеткой сети ANFIS для аппроксимации ФВ ЛПР система вывода функционально эквивалентна нечеткой системе вывода Сугено, которая реализуется за два шага [10]. На первом шаге осуществляется формирование базы знаний, построение нечеткой системы вывода Сугено и грубая настройка модели. На втором шаге осуществляется тонкая настройка модели, состоящая в подборе таких значений параметров функции принадлежности, которые минимизируют разницу между физическими и модельными значениями выходной переменной.

Предположим, что было выполнено N экспериментов для определения значений логической переменной ζ , в результате чего в n_1 экспериментах переменная ζ приняла значение ζ_1 , в n_2 экспериментах – значение ζ_2 , и т.д. как прежде n_e и ζ_e .

Обозначим вектора входа A как

$$A_{i,j} = (\alpha_{i,j,1}, \alpha_{i,j,2}, \dots, \alpha_{i,j,k}) \in D_A, i = \overline{1, e}, j = \overline{1, n_i}.$$

Обозначим матрицу знаний $\{\alpha_{i,j,l}, i = \overline{1, e}, j = \overline{1, n_i}, l = \overline{1, k}\}$ в виде

$$\bigcup_{j=1}^{n_i} \left(\bigcap_{l=1}^k (\alpha_j = \alpha_{i,j,l}) \right) \rightarrow \zeta_i = a_{0i} + a_{1i}\alpha_1 + a_{2i}\alpha_2; i = \overline{1, e}. \quad (8)$$

База знаний Сугено имеет отличие от базы знаний Мамдани в том, что заключения правил задаются не нечеткими термами, а линейной функцией входов.

При использовании алгоритма Сугено первый этап его реализации применительно к задаче аппроксимации функции $\zeta(A)$ совпадает с алгоритмом вывода Мамдани и включает следующие операции: фазификацию, агрегирование, активацию, акумуляцию, дефазификацию [10]. На втором этапе производится тонкая настройка модели $\zeta(A)$, которая заключается в настройке параметров функции принадлежности на основе обучающего множества, осуществляется при помощи нейронной сети, приведенной на рис. 1. Назначение слоев нейронной сети систематизированы в табл. 1.

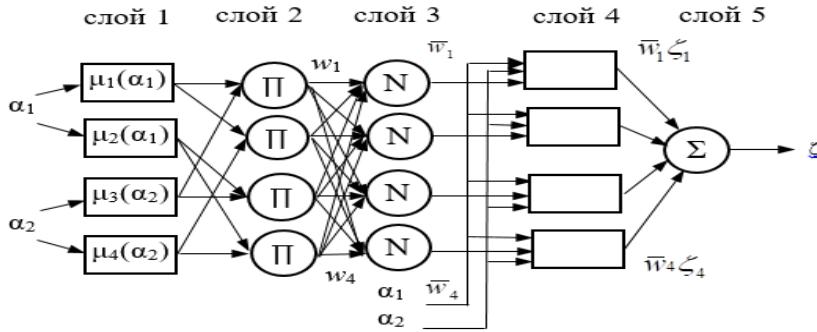


Рис. 1. Структура нейро-нечеткой сети ANFIS

Таблица 1. Назначение слоев нейронной сети ANFIS

Номер слоя	Назначение нейронов слоя	Выход слоя
1	Представление термов входных переменных	Значения функций принадлежности $\mu_1(\alpha_1), \mu_2(\alpha_1), \mu_3(\alpha_2), \mu_4(\alpha_2)$
2	Антецеденты нечетких правил	Степени истинности предпосылок w_1, w_2, w_3, w_4 правил базы знаний системы
3	Нормализация степеней выполнения правил	Отношения степени истинности предпосылок $\bar{w}_1, \bar{w}_2, \bar{w}_3, \bar{w}_4$ правил к сумме степеней предпосылок всех правил $\bar{w}_i = \frac{w_i}{\sum_{i=1}^4 w_i}$
4	Вычисление заключений правил	$\bar{w}_1\zeta_1, \bar{w}_2\zeta_2, \bar{w}_3\zeta_3, \bar{w}_4\zeta_4; \zeta_i = a_{0i} + a_{1i}\alpha_1 + a_{2i}\alpha_2;$ $\{a_{0i}, a_{1i}, a_{2i}\}$ - параметры вывода
5	Агрегирование результата, полученного по различным правилам	Выходное значение сети ζ

Для обучения сети ANFIS на различные практике используются методы: метод обратного распространения ошибки, гибридный метод и эволюционные алгоритмы [12].

Для оценки погрешности нечеткой нейронной сети используется функция ошибки

$$\Omega(a, b, a_0, a_1, a_2) = \frac{1}{N} \sum_{i=1}^N (\zeta(A_i) - \bar{\zeta}(A_i))^2 \rightarrow \min_{a, b, A}, \quad (9)$$

где $\zeta(A_i), \bar{\zeta}(A_i)$ – фактическое значение выходной переменной и результат нечеткого логического вывода в точке A_i ; a, b – параметры функций принадлежности первого слоя нечеткой нейронной сети; $A = \{a_0, a_1, a_2\}$ – множество параметров четвертого слоя нечеткой нейронной сети.

По мере решения задачи оптимизации система вывода ANFIS приобретает новые знания, что приводит к необходимости изменения топологии нечеткой нейронной сети. Модификация топологии нечеткой нейронной сети может быть осуществлена по методике, предложенной в работе [11].

Практическое применение. Описанная выше методика для решения многоокритериальной оптимизационной задачи была реализована в отношении технической системы экологически чистой защиты плодовых растений от паразитов. В частности, рассмотрена техническая система электро-импульсной обработки томатов для борьбы с корневой нематодой [3].

Математическая модель процесса электро-импульсной обработки томатов в безразмерном масштабе имеет следующий вид:

$$y_1 = 1.587 - 0.537 * x_1 - 0.460 * x_2 - 1.365 * x_3 + 0.299 * x_1^2 + 0.671 * x_2^2 + 1.551 * x_3^2; \\ y_2 = 1400 + 50 * A_1^2 * A_2, \quad (10)$$

где $x_i = \frac{z_i - z_i^0}{\Delta z_i}; i = \overline{1, 3}; z_i^0 = \frac{(z_{i\max} + z_{i\min})}{2}; \Delta z_i = \frac{(z_{i\max} - z_{i\min})}{2}; A_1 = 2500 * x_1 + 3500;$

$A_2 = (936 * x_3 + 1064) * 10^{-10}$; z_1 – электрическое напряжение на выходе трансформатора, В; z_2 – длитель-

нность электрического импульса, сек.; z_3 – емкость конденсатора, пФ; y_1 – коэффициент омертвления, %; y_2 – мощность, потребляемая технической системой, Вт.

Задача оптимизации процесса обработки растений электрическим разрядом имеет следующую постановку

$$\begin{aligned} y_1(z) &\rightarrow \min_{z \in \Omega_z} \\ y_2(z) &\rightarrow \min_{z \in \Omega_z}, \end{aligned} \quad (11)$$

где $\Omega_z = \left\{ z \in R^n \mid g_1(z) \leq 0; g_2(z) \leq 0; z_{j_{\min}} \leq z_j \leq z_{j_{\max}}; j = \overline{1, 3} \right\}$ – множество допустимых решений; $z_{j_{\min}} \leq z_j \leq z_{j_{\max}}; j = \overline{1, 3}$ – прямые ограничения на входные параметры технической системы; $g_1(z) \leq 0; g_2(z) \leq 0$ – функциональные ограничения на выходные параметры процесса $y_1 - t_1 \leq 0; y_2 - t_2 \leq 0; t_1, t_2$ – заданные значения.

При переходе к безразмерному масштабу множество допустимых решений определяется как:

$$\begin{aligned} W = Y Z X = \{ Y OR^k \mid &y_1 \geq t_1; y_2 \geq t_2; t_1 = 1,5\%; t_2 = 1500 \text{ W}; \\ &X OR^n \mid 1.215 \geq x_i \geq 1.215; i = 1, 3 \}. \end{aligned} \quad (12)$$

Оценки рассеяния значений выходных параметров выбирались следующим образом: по параметру $y_1(z)$ $d_1 = 0.01$, по параметру $y_2(z)$ $d_2 = 10$. Множество достижимости приведено на рис. 2.

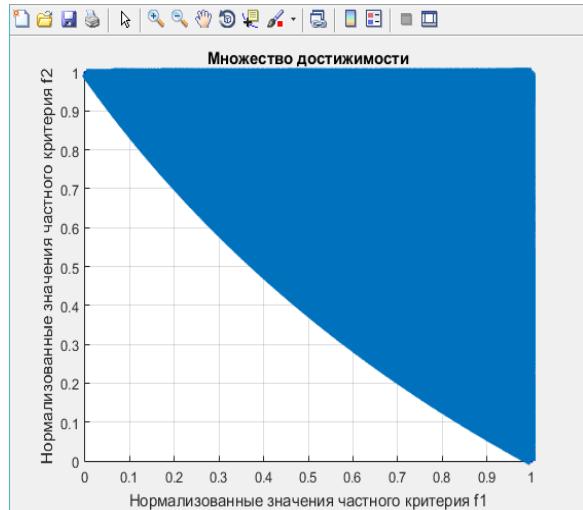


Рис. 2. Множество достижимости

Задача оптимизации в постановке (3) решалась методом покоординатного спуска, задача (5) определения максимума значений функции $\zeta(A)$ решалась методом золотого сечения.

Программная реализация задачи многоокритериальной оптимизации процесса электро-импульсной обработки томатов осуществлялась в программной среде MATLAB 9.7.0 на персональном компьютере с процессором DualCore Intel Pentium G4560, 3500 ГГц и оперативной памятью 8 Гбайт. Построение и обучение нейро-нечеткой сети ANFIS осуществлялось в следующей последовательности.

Шаг 1. Было выбрано количество «разгонных» решений n , равное шести: A1, A2, ..., A6. Причем, крайние значения A1, A6 выбирались на границах области изменения весового коэффициента α_1 ; $\alpha_2 = 1 - \alpha_1$, а средние значения A2, A3, ..., A5 генерировались случайным образом.

Шаг 2. Осуществлялось решение задачи многоокритериальной оптимизации в постановке (3) в сгенерированных точках. Результат решения задачи многоокритериальной оптимизации отражен в таблице 2. По данным табл. 2 был сформирован файл NTrain, в которых были помещены данные для обучения нейро-нечеткой сети ANFIS.

Шаг 3. Загружался редактор нейро-нечеткой сети ANFIS командой anfisedit и выборка обучающих данных загружалась из файла NTrain.dat. Открывающееся окно редактора показано на рис. 3.

Таблица 2. Результат решения задачи (3) для сгенерированных точек

Номер итерации	α_1	y_1	y_2	ζ
1	0	5.1047568443647364	1400.8827636960002	2
2	0.32	1.0750077064829138	1530.0137542173500	3
3	0.12	1.3958051053281146	1445.3261712921521	5
4	0.59	0.98763860425667394	1588.7361794377134	3
5	0.26	1.1235524778705630	1511.6352390201871	3
6	1	0.96672483777880258	1643.5552385593733	2

Шаг 4. Осуществлялась генерация структуры системы нечеткого вывода FIS типа Сугено, которая выполнялась после нажатия кнопки Generate FIS. После этого открывалось диалоговое окно с указанием числа и типа функций принадлежности для отдельных термов входных переменных и выходной переменной, приведенных на рис. 4.

Шаг 5. Осуществлялся выбор типа функций принадлежности, в нашем случае gaussmf – функция распределения Гаусса. При нажатии кнопки Structure осуществлялась визуализация структуры, полученной в результате системы нечеткого вывода FIS, которая приведена на рис. 5.

Шаг 6. Был выбран метод обучения гибридной сети, в нашем случае hybrid- комбинация методов наименьших квадратов и убывания обратного градиента. При этом уровень ошибки обучения – Error Tolerance по умолчанию задавался равным нулю. Количество циклов обучения – Epochs задавалось равным 40. После нажатия кнопки Train Now осуществлялась визуализация хода процесса обучения в окне, показанном на рис. 6.

Также становится возможным получить доступ к графическому редактору FIS, графическому интерфейсу для просмотра правил и графическому интерфейсу для просмотра поверхности сгенерированной системы нечеткого вывода.



Рис. 3. Окно редактора нейро-нечеткой сети ANFIS

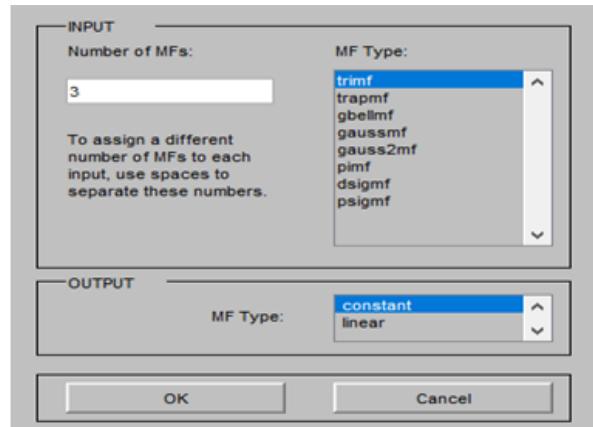


Рис. 4. Окно редактора нейро-нечеткой сети ANFIS

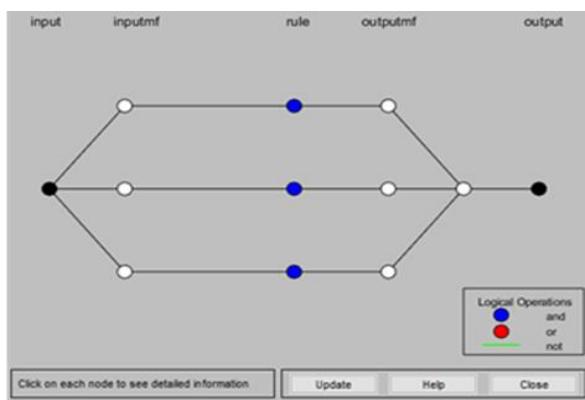


Рис. 5. Структура нейро-нечеткой сети

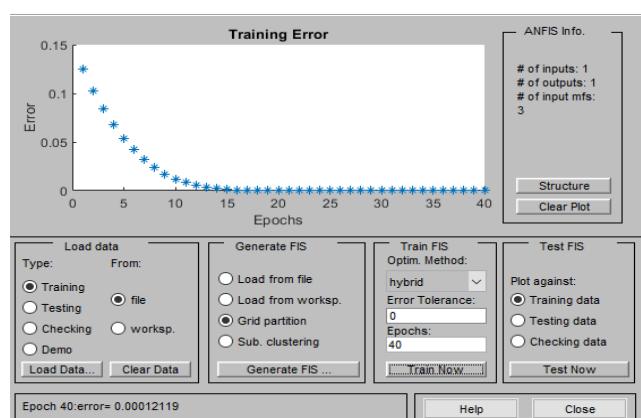


Рис. 6. График процесса обучения

После трех дополнительных итераций был получен окончательный результат, который приведен в табл. 3.

Таблица 3. Результат решения задачи (5)

Номер итерации	α_1	y_1	y_2	ζ
1	0	5.1047568443647364	1400.8827636960002	2
2	0.32	1.0750077064829138	1530.0137542173500	3
3	0.12	1.3958051053281146	1445.3261712921521	5
4	0.59	0.98763860425667394	1588.7361794377134	3
5	0.26	1.1235524778705630	1511.6352390201871	3
6	1	0.96672483777880258	1643.5552385593733	2
7	0.110	1.4344381614368813	1449.2470500028558	5
8	0.115	1.4145439760325877	1451.8033668132491	5
9	0.102	1.4684684525152787	1445.1430662691575	5

Графический интерфейс для просмотра правил, сгенерированных на девятом шаге итераций системы нечеткого вывода, показан на рис. 7. Функция предпочтения лица, принимающего решения, на девятом шаге итераций после сглаживания кубическим сплайном показана на рис. 8.

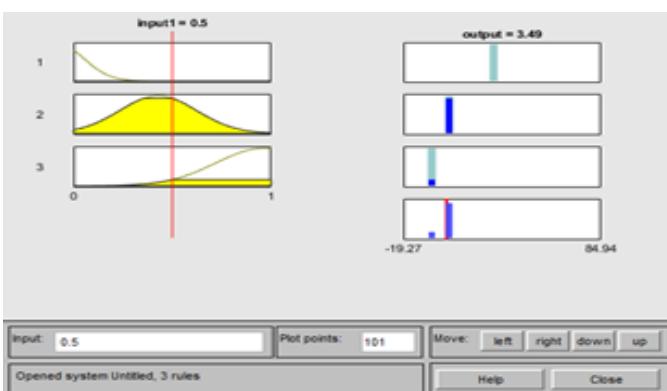


Рис. 7. Интерфейс сгенерированных

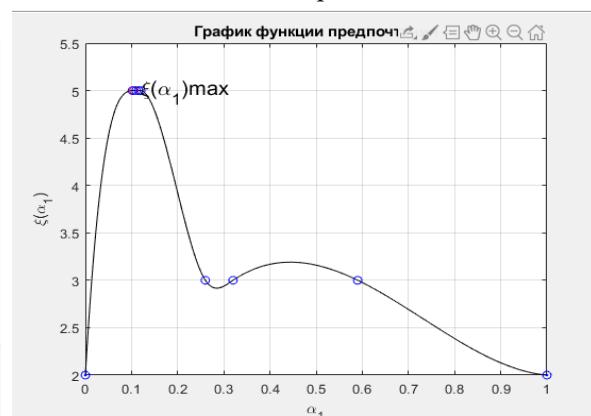


Рис. 8. Вид функции принадлежности на девятом шаге итераций Рис. 1. Структура нейро-нечеткой сети ANFIS

Окончательный результат решения многокритериальной задачи оптимизации электроимпульсной обработки томатов заключается в следующем: $\alpha_1 = 0.102$; $\alpha_2 = 0.898$; $x_1 = -0.4797$; $x_2 = 0.4285$; $x_3 = 0.4449$; $z_1 = 2540$ В; $z_2 = 0.167$ сек.; $z_3 = 1397$ ПФ; $y_1 = 1.46\%$ и $y_2 = 1445$ Вт.

Заключение

1. Предложенная методика оптимального параметрического синтеза технических систем позволяет обойти вычислительные трудности, связанные с многокритериальностью и некорректностью задачи.

2. Описанный алгоритм интеллектуальной поддержки принятия решений дает возможность решения задачи многокритериальной оптимизации параметров технических систем в условиях неопределенности приоритетов по частным критериям оптимальности.

3. Программная реализация разработанного интеллектуального алгоритма многокритериальной оптимизации на примере системы электроимпульсной обработки сельскохозяйственных растений показала его высокую эффективность и работоспособность. Таким образом, можно сделать вывод о перспективности широкого применения предложенных методики и интеллектуального алгоритма в решении задач многокритериальной оптимизации различных технических систем.

ЛИТЕРАТУРА

1. Тихонов, А. Н., Гончарский А. В., Степанов В. В., Ягода А. Г. Регуляторные алгоритмы и априорная информация, М., Наука, 1990. – 230 с.
2. Кабильджанов, А. С. Нечеткая аппроксимация в задачах оптимального параметрического синтеза технических объектов. – журнал «Проблемы информатики и энергетики». Ташкент, № 5. – 2016. – С. 23–32.
3. A. S. Kabildjanov, E. O. Bozorov, Ch.Z. Okhunboboeva. Optimization and Simitation of the Process Electro Impulse Treatment of Plants/ Exploring Innovation | ISSN: 2249-8958 (Online) | Reg. No.: C/819981 | Published By BEIESP | B Impact Factor: 5.97 | Scopus Journal Inter-national Journal of Engineering and Advanced Technology (IJEAT), Volume-9 Issue-1, October 2019 P. 4850–4853.
4. Кабильджанов, А. С. Принятие решений при статической оптимизации биотехнологических процессов в условиях частичной неопределенности. Журнал «Проблемы вычислительной и прикладной математики», Ташкент, № 1, 2015. – С. 94–101.
5. Черноруцкий, И. Г. Оптимальный параметрический синтез. Электротехнические устройства и системы. – Л.: Энергоиздат, 1987. – 110 с.
6. Ларичев, О. И., Горвиц Г. Г. Методы поиска локальных экстремумов овражных функций. М.: Наука, 2003. – С. 5–12.
7. Моисеев, Н. Н. Математические задачи системного анализа. – М.: Наука, 1981. – 488 с.
8. Леоненков, А. В. Нечеткое моделирование в среде MATLAB и fuzzyTECH / А. Леоненков. - СПб: БХВ-Петербург, 2005. – 736 с.
9. Мухлисуллина, Д. Т., Моор Д. А., Карпенко А. П. Многокритериальная оптимизация на основе нечеткой аппроксимации функции предпочтений лица, принимающего решения // Электронное научно-техническое издание: наука и образование. – 2010. – № 1. (<http://technomag.edu.ru/doc/135375.html>).
10. Карпенко, А. П., Мур Д. А., Мухлисуллина Д. Т. Нейронные сети, нечеткие и нейро-нечеткие приближения в задаче многокритериальной оптимизации // Электронное научно-техническое издание: наука и образование. – 2010. – № 6. – С. 60–66.
11. Круглов, В. В. Искусственные нейронные сети. Теория и практика / В. В. Круглов В. В. Борисов. – М.: Горячая линия – Телеком, 2002. – 382 с.
12. Дьяконов, В. П., Круглов В. В. MATLAB 6.5 SP1 / 7/7 SP1 / 7 SP2 + Simulink 5/6. Инструменты искусственного интеллекта и биоинформатика. Серия «Профессиональная библиотека». М.: СОЛОН-ПРЕСС, 2010. – 456 с.