

УДК 004.93



ГИБРИДНЫЙ МУЛЬТИАГЕНТНЫЙ ПОДХОД ДЛЯ ПОСТРОЕНИЯ НЕЙРО-ФАЗЗИ МОДЕЛЕЙ В ЗАДАЧАХ ДИАГНОСТИКИ

А.А. Олейник¹, С.А. Субботин²¹ Запорожский национальный технический университет, г. Запорожье, Украина, olejnik@zntu.edu.ua;² Запорожский национальный технический университет, г. Запорожье, Украина, subbotin@zntu.edu.ua

Исследуется мультиагентный подход для моделирования сложных объектов и систем. Разработан гибридный мультиагентный метод структурно-параметрического синтеза нейро-фаззи сетей. Решена практическая задача моделирования основных параметров авиадвигателей.

ОПТИМИЗАЦИЯ, КОЛЛЕКТИВНЫЙ ИНТЕЛЛЕКТ, АГЕНТ, ВЫБОРКА, НЕЧЁТКАЯ ЛОГИКА, НЕЙРО-ФАЗЗИ СЕТИ

Введение

В настоящее время диагностики и прогнозирования работы сложных технических объектов и процессов являются необходимым элементом производства, поскольку позволяют сократить издержки от выпуска дефектной или ненадёжной продукции. Одним из весьма эффективных средств автоматизации принятия диагностических решений являются нейро-фаззи сети, преимуществами которых являются логическая прозрачность и незначительные затраты материальных ресурсов на программную и аппаратную реализацию [1, 2]. Благодаря этому нейро-фаззи сети нашли широкое применение на практике [3, 4].

Однако нерешённой остаётся задача оптимального синтеза нейро-фаззи сети, обеспечивающего наилучшее соотношение структуры сети и настраиваемых параметров. Существующие методы преимущественно направлены на решение задачи параметрической идентификации, в то время, как структура задаётся экспертным путём. Помимо того, традиционные методы настройки нейро-фаззи сетей, основанные на использовании техники обратного распространения ошибки, выдвигают требование дифференцируемости функций принадлежности, что, в свою очередь, ограничивает выбор структуры сети. В связи с этим актуальной является задача разработки новых методов структурно-параметрического синтеза нейро-фаззи сети, которые бы обеспечивали одновременно и подбор структуры сети, и её настройку без ограничений на функции принадлежности и другие параметры сети.

Для решения задачи структурно-параметрического синтеза нейро-фаззи сетей предлагается использовать методы коллективного интеллекта [5, 6]. Среди наиболее известных методов коллективного интеллекта можно выделить метод муравьиных колоний (Ant Colony Optimization, ACO) [7, 8], метод пчелиной колонии (Bee Colony Optimization, BCO) [9, 10], метод оптимизации с использованием роя частиц (Particle Swarm Optimization, PSO) [11] и другие [12, 13]. Основными преимущества-

ми методов, основанных на моделировании коллективного интеллекта, являются: мультиагентная реализация, отсутствие требований к оптимизируемому параметрам, способность решать задачи как дискретной, так и непрерывной оптимизации.

Целью данной работы является исследование методов коллективного интеллекта, а также разработка мультиагентного метода структурно-параметрического синтеза нейро-фаззи сетей, основанного на моделировании коллективного интеллекта с прямой и не прямой связью между агентами. В работе исследуются два наиболее известных метода роевого интеллекта, использующие различные подходы к реализации связей между агентами: метод АСО и метод ВСО, основанные на моделировании не прямой и прямой связи между агентами соответственно.

1. Постановка задачи

Пусть задано множество нечётких продукционных правил Ω вида “ЕСЛИ $\langle A \rangle$, ТО $\langle B \rangle$ ”, а также задана архитектура нейро-фаззи сети, на основе которой должна моделироваться аппроксимируемая зависимость, описанная при помощи заданного множества нечётких правил Ω . Тогда задача структурно-параметрического синтеза нейро-фаззи сети заключается в том, что для заданной архитектуры сети (Сугено или Мамдани) необходимо определить оптимальную структуру путём получения редуцированной базы нечётких правил Ω' и настроить коэффициенты функций принадлежности Θ , при которых обеспечивалась бы допустимая ошибка прогнозирования $\varepsilon_{\text{доп}}$: $\varepsilon < \varepsilon_{\text{доп}}$.

2. Сравнительный анализ методов АСО и ВСО

Метод АСО [6–8] представляет собой эвристический, итеративный, мультиагентный метод интеллектуальной оптимизации с не прямой связью между агентами, основанный на случайном поиске. Основной идеей метода АСО является моделирование поведения в процессе фуражировки муравьёв, реализующиеся в методе с помощью программных агентов. Особенностью такой фуражировки является выделение феромонов, которые

агенты оставляют на пути при своём перемещении. Феромоны также в процессе работы метода испаряются с течением времени. Таким образом достигается то, что на наилучшем пути остаётся большее количество феромонов, поскольку добавление феромонов происходит чаще, чем испарение. А так как выбор пути для перемещения агентов основывается на информации о количестве феромонов, то агенты выбирают лучший путь.

Метод ВСО также является эвристическим, итеративным, мультиагентным методом интеллектуальной оптимизации, основанным на случайном поиске, но с прямой связью между агентами. Данный метод моделирует процесс фуражировки пчёл. Главной особенностью данного метода является дифференциация задач агентов. В связи с этим существуют агенты трёх типов: разведчики, которые ищут новые решения, занятые фуражиры, разрабатывающие уже найденные решения (что обеспечивает локальную оптимизацию) и незанятые фуражиры, которые ничем не заняты, а ожидают момента, когда смогут начать участвовать в поисках лучшего источника нектара. За счёт такого разделения функций агентов достигается углублённое изучение уже найденных решений (с помощью занятых фуражиров) и изучение пространства поиска в целом (с помощью агентов-скаутов). Связь между агентами в методе пчелиной колонии обеспечивается за счёт моделирования виляющего танца агентами, что обеспечивает прямую связь между агентами.

Можно видеть, что метод АСО и метод ВСО обладают рядом сходных свойств:

- стохастичность: оба метода представляют собой методы случайного поиска;
- мультиагентность: методы реализуются с помощью агентно-ориентированного подхода;
- итеративность: для нахождения оптимума необходимо выполнить достаточно большое количество итераций;
- гарантированность оптимизации: сходимость к оптимальному решению гарантируется, но время сходимости заранее не определено;

- скорость нахождения оптимального значения выше, чем у традиционных методов оптимизации;
- трудность теоретического анализа процесса нахождения оптимума;
- зависимость от начальных параметров.

Между методом АСО и методом ВСО присутствуют также определённые различия. Данные различия приведены в табл. 1.

Исходя из представленных различий между методом АСО и методом ВСО, можно сделать вывод, что метод ВСО лучше применять для задач непрерывной оптимизации, поскольку в нём выполняется дифференциация агентов, за счёт которого достигается улучшенное изучение локальных уже найденных областей с источниками нектарами, а метод АСО лучше применять для задач дискретной оптимизации, поскольку в нём выполняется динамическое изменение состояния среды посредством добавления и испарения феромона, что позволяет исключить худшие и выделить лучшие дискретные значения параметров.

3. Метод структурно-параметрического синтеза, основанный на мультиагентном подходе с прямой и непрямой связью между агентами

Структурно-параметрический синтез нейрофаззи сетей включает в себя два основных этапа: структурную идентификацию и параметрическую идентификацию сети. При этом эти два вида идентификации должны взаимно влиять друг на друга. Данный подход может быть реализован при конвейерной работе двух основных этапов.

Поскольку мультиагентный подход с непрямой связью хорошо зарекомендовал себя при решении задач дискретной оптимизации [6–8], то предлагается применить его для структурной идентификации, в то время как для параметрической идентификации предлагается использовать мультиагентный подход с прямой связью между агентами. Таким образом, предлагается использовать гибридный мультиагентный подход с прямой и непрямой связью между агентами для структурно-параметрической идентификации нейро-фаззи сетей.

Таблица 1

Различия между методом АСО и методом ВСО

Критерий	АСО	ВСО
Класс решаемых задач	Дискретная оптимизация	Дискретная и непрерывная оптимизация
Локальная оптимизация	Отсутствует	Выполняют агенты специального типа – занятые фуражиры
Связь между агентами	Непрямая: с помощью феромона, который характеризует внешнюю среду	Прямая: посредством выполнения виляющего танца, который выполняют определённые агенты
Дифференциация задач агентов	Отсутствует	Присутствует: одни агенты ищут новые решения, другие – разрабатывают старые
Динамическое изменение состояния среды	Выполняется посредством изменения количества феромона	Отсутствует

Структурная идентификация предполагает преобразование входной базы нечётких правил, поскольку структура нейро-фаззи сети изоморфна базе нечётких правил, то есть структура определяется базой нечётких правил. В связи с этим структурная идентификация будет выполняться в пространстве нечётких термов, которые будут объединяться в новые правила. В свою очередь параметрическая идентификация предполагает выбор наиболее оптимальных параметров функций принадлежности и весов нечётких правил.

Разработанный гибридный мультиагентный метод структурно-параметрического синтеза нейро-фаззи сетей с прямой и непрямой связью между агентами можно представить в виде последовательности следующих шагов.

Шаг 1. Инициализация. Задать параметры работы метода: $\beta, \rho, \gamma, t_b^{\max}, t_a^{\max}, t^{\max}$. Установить счётчики итераций: общий счётчик $t=0$; счётчик итераций параметрической идентификации $t_b=0$; счётчик итераций структурной идентификации $t_a=0$. Установить начальную структуру $FN(0)$, соответствующую исходной базе нечётких правил.

Шаг 2. Установить счётчик итераций: $t = t + 1$. Задать верхние и нижние пределы изменения значений для всех параметров нечёткой модели: $range^{\max}$ и $range^{\min}$.

Шаг 3. Создание агентов с начальными случайными решениями. Создать B_s агентов, размещённых в случайных позициях пространства поиска:

$$x_j^i = rand \cdot (range_j^{\max} - range_j^{\min}) + range_j^{\min}, \\ \forall i = \overline{1, B_s}, j = \overline{1, vCnt},$$

где x_j^i – координата в j -ом измерении i -го агента; $rand$ – случайное число в интервале $[0; 1]$.

Для всех позиций, в которые были помещены агенты случайным образом, рассчитывается их полезность. В данном случае полезность точки пространства поиска определяется ошибкой прогнозирования модели с параметрами, которые соответствуют значениям координат данной позиции:

$$prof^i = \varepsilon [FN(x_1^i, x_2^i, \dots, x_{vCnt}^i)], \forall i = \overline{1, B_s},$$

где $prof^i$ – полезность точки пространства поиска, в которой находится i -ый агент.

Установить текущую итерацию параметрической идентификации $t_b = 0$, текущую температуру $T = T_{init}$, количество агентов-разведчиков $B = B_s$.

Шаг 4. Установить: $t_b = t_b + 1$.

Шаг 5. Выбор рабочих агентов. Отбор рабочих выполняется за счёт моделирования процедуры имитации отжига, то есть агент относится к рабочим, если выполняется следующее условие:

$$\exp\left(-\frac{|prof^i - prof^{best}|}{T}\right) > rand, \forall i = \overline{1, B},$$

где $prof^{best}$ – полезность позиции, в которой обеспечивается наименьшая ошибка прогнозирования.

Шаг 6. Скрещивание. Данный шаг позволяет создать агентов, которые бы находились в позициях с лучшими характеристиками за счёт пересечения между координатами позиций определённой группы агентов. Для скрещивания используются отобранные на шаге 5 рабочие агенты и агент, который находится в лучшей точке пространства поиска. На основе скрещивания создаются агенты, которые перемещаются в позиции, определяемые следующим образом:

$$x_j^{new} = x_j^{work} + rand(-1; 1) \cdot (x_j^{work} - x_j^{best}), \\ \forall j = \overline{1, vCnt}, work = \overline{1, B_w},$$

где B_w – количество агентов, которые были отнесены к рабочим; $rand(-1; 1)$ – случайное число, выбранное из интервала $[-1; 1]$.

Для созданных новых агентов рассчитывается полезность их пребывания в выбранных точках пространства поиска:

$$prof^{new} = \varepsilon [FN(x_1^{new}, x_2^{new}, \dots, x_{vCnt}^{new})], \forall i = \overline{1, B_n},$$

где B_n – количество агентов, созданных в результате скрещивания.

Шаг 7. Моделирование обмена информацией. В результате выполнения обмена информацией достигается вербовка одних агентов другими. Завербованные агенты используются для улучшенного изучения уже найденных областей пространства поиска. Моделирование обмена информацией производится путём выполнения последовательности шагов 7.1–7.4.

Шаг 7.1. Нормирование полезностей агентов:

$$np^i = 1 - \frac{prof^i}{prof_{\max} - prof_{\min}},$$

где np^i – нормированная полезность i -го агента; $prof_{\max}$ и $prof_{\min}$ – максимальная и минимальная полезности среди всех агентов, соответственно.

Шаг 7.2. Добавление шумов в полученные нормированные полезности и корректировка нормированных полезностей:

$$np^i = \begin{cases} 1, & \text{если } np^i + w^i > 1; \\ np^i + w^i, & \text{если } e_n < np^i + w^i < 1; \\ 0, & \text{если } 0 < np^i + w^i < e_n, \end{cases}$$

где w^i – шум в полезности. Шум равномерно распределён в пределах $(-w; +w)$. Значение w выбирается экспериментально, e_n – минимальный порог полезности, выбираемый экспериментально.

Шаг 7.3. Определяются достоинства решения каждого агента:

$$L^i = \max\{np^i - \eta \cdot \overline{np}, 0\},$$

где L^i – достоинство решения i -го агента; η – коэффициент, управляющий влиянием величины \overline{np} на L^i ; \overline{np} – среднее значение нормированной полезности всех агентов, допущенных к моделированию обмена информацией.

Шаг 7.4. Выбор агентов, которые считаются выполнившими вербовку других агентов для улучшенного изучения найденных ранее решений. Агент считается выполнившим вербовку, если:

$$\frac{L^i}{\beta} > \gamma \cdot \overline{np}, \forall i = \overline{1, B_c},$$

где B_c – количество агентов, допущенных к вербовке; $\beta > 0$ – коэффициент, понижающий влияние достоинства решения на вероятность выполнения вербовки; $\gamma \in (0; 1)$ – пороговой коэффициент, определяющий, насколько выше должно быть достоинство решения i -го агента относительно средней полезности решений всех B_c агентов.

Шаг 8. Перезапуск агентов, выполняющих параметрическую идентификацию. Создаются агенты, которые будут рассматриваться как агенты-разведчики для следующей итерации.

К новым агентам-разведчикам будут относиться:

– агенты, выполнившие посредством танца вербовку;

– агенты, которые стали занятыми фуражирами вследствие вербовки. Поскольку такие агенты должны выполнять улучшенное изучение уже существующей области с решением, то при создании решений для данных агентов должны учитываться решения завербовавших их агентов. В связи с этим для завербованных агентов решение создаётся следующим образом:

$$x_j = x_j^d + range \cdot rand - \frac{range}{2}, \forall j = \overline{1, vCnt},$$

где $range$ – это предел, в котором величина переменной может отклоняться от значения данной j -ой переменной x_j^d в решении агента, моделировавшего обмен информацией;

– агенты, решение которых создаётся случайным образом:

$$x_j = rand \cdot (range_j^{\max} - range_j^{\min}) + range_j^{\min}, j = \overline{1, vCnt}.$$

Также для всех созданных агентов рассчитывается полезность выбранного решения.

Шаг 9. Обновление параметров, влияющих на параметрическую идентификацию:

– изменяется текущая температура: $T = \alpha \cdot T$;

– изменяется предел $range$:

$$range = range \cdot \frac{t_b^{\max} - t_b}{t_b^{\max}}.$$

Шаг 10. Проверка на достижение оптимальных параметров для текущей структуры сети. Провер-

ка считается успешной, если выполняется одно из следующих условий:

– достигнуто максимальное количество итераций: $t_b = t_b^{\max}$;

– текущая температура равна конечной температуре: $T = T_{final}$;

– ошибка прогнозирования лучшей нейро-фаззи сети находится в допустимых рамках для параметрического синтеза: $\varepsilon_{best} < \varepsilon^*$.

Если проверка на останов дала успешный результат, тогда установить $\varepsilon(t) = \varepsilon_{best}$ и выполнить переход на шаг 11, в противном случае – на шаг 4.

Шаг 11. Сравнение качества прогнозирования текущей структуры нейро-фаззи сети с качеством прогнозирования предыдущей сети. Проверяется условие:

$$\varepsilon(t-1) < \varepsilon(t),$$

где $\varepsilon(t)$ – ошибка лучшей нейро-фаззи сети, полученной на итерации t .

Если условие выполняется, тогда установить: $FN(t) = FN(t-1)$; $\varepsilon(t) = \varepsilon(t-1)$. То есть, если на предыдущей итерации была получена нейро-фаззи сеть с лучшими характеристиками, то на следующей итерации должно выполняться сравнение с сетью, полученной на этой итерации. Если же вновь полученная сеть (на итерации t) характеризуется лучшими характеристиками, то на следующей итерации сравнение будет производиться с ней. За счёт такого подхода выявляется лучшая структура и лучшие параметры для неё на протяжении всей работы метода.

Шаг 12. Создание пространства поиска. Для каждого класса возможных значений выходной переменной создаётся отдельный граф поиска, по которому перемешаются отдельные агенты. У каждого графа поиска вершинами являются лингвистические термы, а рёбра формируются при перемещении агентов и наличие ребра свидетельствует о том, что связанные им термы входят в правило, сформированное агентом, который перемешался между ними. Для каждой вершины каждого графа поиска рассчитывается эвристическая значимость:

$$\eta_p^q = \frac{\sum_{o=1}^N \min(\mu_p(o), \mu_q(o))}{\sum_{o=1}^N \mu_q(o)}, \forall p = \overline{1, T}, q = \overline{1, K},$$

где η_p^q – значение эвристической значимости лингвистического термина p для описания класса q ; o – экземпляр входной выборки, содержащей N экземпляров; $\mu_p(o), \mu_q(o)$ – значение функции принадлежности объекта o терму p и классу q , соответственно; T – количество лингвистических термов; K – количество классов.

В каждом графе поиска каждому узлу графа поиска ставится в соответствие начальное значение количества феромонов: τ_{init} :

$$\tau_p^q(1) = \tau_{init}, \forall p = \overline{1, T}, q = \overline{1, K},$$

где $\tau_p^q(1)$ – значение количества феромонов для p -го терма в пространстве поиска для q -го класса на первой итерации поиска.

Шаг 13. Установить счётчик итераций для структурной идентификации: $t_a = t_a + 1$.

Шаг 14. Перемещение агентов.

Шаг 14.1. Выбор следующего терма для перемещения в него. При перемещении j -ый агент принимает решение о перемещении в k -ый лингвистический терм i -го пространства поиска при выполнении следующего условия:

$$P_k^{i,j} = \frac{\eta_k^i \cdot \tau_k^i(t_a)}{\sum_{p \in R^j} \eta_p^i \cdot \tau_p^i(t_a)} > rand,$$

где $P_k^{i,j}$ – вероятность добавления k -го терма в правило j -го агента в пространстве поиска для i -го класса; R^j – множество термов, которые могут быть добавлены в правило j -го агента. Формирование данного множества определяет вид правил, которые могут составляться в процессе поиска, то есть предполагается, что если правило может включать выражения типа ИЛИ, то после добавления терма из данного множества исключается только данный терм, если же предполагается, что правило не может включать выражения типа ИЛИ, то кроме выбранного терма, исключаются и все термы, использующиеся для описания соответствующего атрибута.

Шаг 14.2. Проверка на окончание перемещения. Перемещение может быть закончено, если агент уже посетил все возможные вершины графа поиска или если достигнуто удовлетворительное количество покрываемых объектов сформированным правилом. В связи с этим для каждого экземпляра o , относящегося к классу i , рассчитывается степень соответствия сформированного правила R_j и экземпляра o :

$$match(R_j, o) = \min(matchAttr(R_j^1, o^1), \dots, matchAttr(R_j^p, o^p), \dots, matchAttr(R_j^Q, o^Q)),$$

где $match(R_j, o)$ – степень соответствия между правилом j -го агента R_j и экземпляром o ; $matchAttr(R_j^p, o^p)$ – мера соответствия между p -ым атрибутом в правиле R_j и соответствующим атрибутом экземпляра o :

$$matchAttr(R_j^p, o^p) = \begin{cases} 1, & \text{если } R_j^p = \emptyset; \\ \max_q(\min(\mu_q(R_j^p), \mu_q(o^p))), & \forall q = \overline{1, Q^p}, \text{ иначе,} \end{cases}$$

где q – отдельный терм, относящийся к области описания атрибута p ; Q^p – количество термов, относящихся к области описания атрибута p .

Далее проверяется условие:

$$match(R_j, o) \geq inMatchMin,$$

где $inMatchMin$ – заданный параметр, который определяет, какое минимальное значения соответствия является достаточным, чтобы считать, что правило R_j в достаточной степени описывает объект o .

Если условие выполняется, то считается, что данный объект o покрывается правилом R_j .

На основании получаемых данных увеличивается счётчик $cntMatch$, в котором хранится количество экземпляров, покрываемых правилом R_j .

Проверяется условие:

$$cntMatch \geq inCntMatchMin_i,$$

где $inCntMatchMin_i$ – предельное минимальное количество экземпляров i -го класса, которое должно покрываться правилом.

Если указанное условие выполняется, то считается, что правило покрывает необходимое количество экземпляров, и j -ый агент завершил своё перемещение, в противном случае – перемещение продолжается.

Шаг 15. Формирование баз правил. Создаётся $nBases$ баз правил, при этом для описания каждого класса выходного значения выбирается одно правило из соответствующего пространства поиска.

Шаг 16. Оценка качества сформированных баз правил. Для оценки качества баз правил для каждого экземпляра исходной выборки определяется правило, наиболее подходящее данному экземпляру, на основе которого определяется расчётный выходной класс для экземпляра. Далее оценивается качество базы правил:

$$Q = \frac{cntMatch}{N},$$

где $cntMatch$ – количество экземпляров, для которых класс был определён верно с помощью заданной базы правил; Q – качество прогнозирования класса экземпляров на основе соответствующей базы правил.

Шаг 17. Добавление феромонов. Добавление феромонов осуществляется для каждого терма, входящего в правило, которое в свою очередь входит в базу правил RB :

$$\tau_p^q(t) = \tau_p^q(t) + Q_{RB} \cdot \tau_p^q(t), \forall p \in R, \forall R \subset RB,$$

где $\tau_p^q(t)$ – количество феромонов для терма p в пространстве поиска для класса q , который определяется с помощью соответствующего правила.

Шаг 18. Испарение феромонов. Испарение феромонов выполняется в соответствии с формулой:

$$\tau_p^q(t+1) = \rho \cdot \tau_p^q(t), \forall p = \overline{1, T}, q = \overline{1, K},$$

где ρ – коэффициент испарения, который задаётся при инициализации.

Шаг 19. Проверка на останов работы агентов по структурной идентификации. Проверка на останов может считаться успешной в одном из двух следующих случаев:

- достигнуто необходимое качество полученной базы нечётких правил: $Q_{high} \geq Q_{threshold}$;
- достигнуто максимальное количество итераций для структурной идентификации: $t_a = t_a^{max}$.

Если проверка на завершение работы по структурной идентификации дала успешный результат, то выполняется переход к шагу 21, в противном случае – к шагу 20.

Шаг 20. Перезапуск агентов, выполняющих структурную идентификацию. Все данные о перемещении агентов во всех пространствах поиска обновляются, агенты размещаются в случайные точки пространств поиска. Переход к шагу 13.

Шаг 21. Проверка на останов работы метода. Останов предлагается производить при выполнении одного из следующих условий:

- построенная нейро-фаззи модель характеризуется требуемой точностью прогнозирования: $\varepsilon < \varepsilon_{доп.}$;
- достигнуто максимальное количество итераций: $t = t^{max}$.

Если проверка на останов была успешной, то выполняется переход к шагу 22, в противном случае – переход к шагу 2.

Шаг 22. Останов.

Таким образом, предложенный метод обеспечивает конвейерный подход при структурно-параметрической идентификации нейро-фаззи модели, за счёт чего обеспечивается взаимовлияние результатов, получаемых при параметрической и структурной идентификации, что обеспечивает получение нейро-фаззи модели, характеризующейся высокой точностью прогнозирования.

4. Эксперименты и результаты

Предложенный гибридный мультиагентный метод структурно-параметрического синтеза нейро-фаззи моделей был программно реализован в среде разработки Matlab 7.0 и использовался для проведения экспериментов по моделированию параметров работы авиадвигателей.

С целью сокращения сроков и снижения стоимости испытаний авиационных двигателей проводятся исследования взаимосвязи основных параметров двигателей (оборотов турбины компрессора n_{tk} , температуры газа перед турбиной T_3 , расхода газа через турбину G_t , температуры на входе в двигатель $T_{вх}$, количества ступеней $N_{ст}$, угла установки лопаток входного направляющего аппарата $\alpha_{ВНА}$, приведенной мощности $N_{пр}$, расхода воздуха G_v , степени сжатия воздуха π_k), наблюдаемых в процессе испытаний, от проходных сечений сопловых аппаратов CA1, CA2, CA3, CA4, контролируемых в производстве, и адиабатического давления B_o .

Сбор экспериментальных данных был выполнен для 125 испытанных двигателей. Результаты получены для номинального режима.

Параметры испытанных двигателей и результаты проливки сопловых аппаратов приведены в табл. 2.

Для построения модели использовалась нейро-фаззи сеть Сугено. Синтезируемая сеть содержала 5 входов, каждый из которых описывался с помощью трёх функций принадлежности. Также сеть содержала базу правил и выход с соответствующей функцией принадлежности.

В качестве функции принадлежности для входов использовалась колоколообразная функция вида:

$$\mu(x, a, b, c) = \frac{1}{1 + \left| \frac{x - c}{a} \right|^{2b}},$$

Таблица 2

Фрагмент обучающей выборки

№	n_{tk}	T_3	G_t	$T_{вх}$	$N_{ст}$	$\alpha_{ВНА}$	$N_{пр}$	G_v	π_k	B_o	CA1	CA2	CA3	CA4
1	95,17	812,1	379,2	-4,8	99,22	6,1	1760,2	8,34	8	763,5	34,86	54,8	98,4	102,19
2	95,03	873,3	379,6	0,7	99,79	6	1753,6	8,3	7,96	763	34,66	55,61	98,4	102,8
3	95,48	835,7	392,8	-1,7	100,01	5,8	1742,1	8,46	7,86	764,5	34,66	55,49	99,15	103,57
4	95,23	830,3	387,6	10,6	100	6,9	1720	8,41	7,75	746	34,88	54,35	99,05	103,57
5	95,02	820,8	382,3	11,2	98,81	7	1731,8	8,35	7,75	743,5	34,88	54,98	98,4	102,5
6	95,31	824,8	384,8	10,8	99,84	5,8	1719,7	8,48	8,04	762	34,88	54,83	99,15	103,37
7	95,21	818,5	382,3	13,3	98,29	5,8	1725,8	8,45	7,98	762,5	34,88	54,35	98,66	101,84
8	95,27	792,5	385,6	14,6	98,61	6,8	1727,3	8,09	7,98	757	34,8	54,41	98,95	103,47
9	95,1	804,2	387,5	15,2	98,86	6,3	1702,5	8,11	7,95	760,5	34,7	54,53	99,15	102,45
10	95,02	812,2	386,9	15,1	99,01	6,5	1728,4	8,41	7,87	749	34,84	54,5	98,4	102,3
...
121	95,15	811	391	6,9	99	6,3	1834	8,28	7,96	754	34,88	54,59	98,35	103,57
122	95,4	795	374	4,3	99,5	5,8	1725	8,27	7,71	762	34,72	54,15	98,55	103,28
123	95,25	840	390	8,6	98,82	6	1737	8,36	7,96	765,5	34,74	54,92	98,9	102,45
124	95,2	819	392	7,2	98,5	6,1	1726	8,35	7,61	766,5	34,6	54,77	99,1	103,57
125	94,8	824	392	7,9	98,88	7,4	1748	8,35	7,85	766	34,6	55,82	98,95	102,63

где a, b, c – параметры, определяющие вид функции: параметр c определяет положение центра функции, значение параметра b обычно положительное.

Полученные значения параметров функций принадлежности для каждого из входов в случае построения нейро-фаззи модели для режима «номинальный» для моделирования n_{tk} представлены в табл. 3.

Средняя относительная ошибка построенной нейро-фаззи модели для n_{tk} составляет $E_{\text{абс.},\text{ннс}} = 0,00001$, что значительно ниже ошибки аналогичной регрессионной модели ($E_{\text{абс.},\text{регр.}} = 0,19505$), что подтверждает эффективность применения нейро-фаззи моделей на практике при диагностировании авиадвигателей.

Средняя относительная ошибка для данных тестовой выборки составила 0,00094, что незначительно хуже ошибки, рассчитанной для данных обучающей выборки. Исходя из рассчитанных значений ошибок нейро-фаззи модели для обучающей и тестовой выборок, можно судить о ее высоких обобщающих способностях и адекватности решаемой задаче.

Для остальных исследуемых зависимостей построены аналогичные нейро-фаззи модели, которые также характеризовались низкой ошибкой при прогнозировании.

Таблица 3

Значения параметров функций принадлежности входов полученной нейро-фаззи модели для прогнозирования n_{tk} в режиме «номинальный»

№ входа	№ μ_f	a	b	c
1	1	6,625	2	740
	2	6,625	2	753,25
	3	6,625	2	766,5
2	1	0,15	2	34,3
	2	0,15	2	34,6
	3	0,15	2	34,9
3	1	0,4775	2	54,15
	2	0,4775	2	55,105
	3	0,4775	2	56,06
4	1	0,875	2	96,7
	2	0,875	2	98,45
	3	0,875	2	100,2
5	1	0,52	2	101,79
	2	0,52	2	102,83
	3	0,52	2	103,87

Выводы

С целью решения актуальной задачи структурно-параметрического синтеза нейро-фаззи сетей в статье разработан гибридный мультиагентный метод с прямой и непрямой связью между агентами.

Научная новизна работы заключается в том, что был разработан новый метод структурно-параметрического синтеза, основанный на гибридном

мультиагентном подходе, который заключается в том, что выполняется конвейерная работа структурной и параметрической идентификации с использованием агентов с непрямой связью и агентов с прямой связью между ними, соответственно. При этом результаты, получаемые на одном из этапов, влияют на работу другого этапа, за счёт чего обеспечивается нахождение оптимальной структуры нейро-фаззи сети и оптимальных параметров к ней.

Практическая ценность работы заключается в том, что решена актуальная задача моделирования основных параметров авиадвигателей в зависимости от проходных сечений сопловых аппаратов и высоты лопаток. Полученные результаты свидетельствуют об эффективности предложенного метода, поскольку построенные модели характеризовались низкой ошибкой прогнозирования.

Работа выполнена в рамках госбюджетной НИР «Научно-методические основы и математическое обеспечение для автоматизации и моделирования процессов управления и поддержки принятия решений на основе процедур распознавания и эволюционной оптимизации в нейросетевом и нечеткологическом базисах» (№ гос. регистрации 0106U008621).

Список литературы: 1. Zadeh, L. Fuzzy sets / L. Zadeh // Information and Control. – 1965. – № 8. – P. 338–353. 2. Mamdani, E. H. An Experiment in Linguistic Synthesis with Fuzzy Logic Controller / E. H. Mamdani, S. Assilian // Int. J. Man-Machine Studies. – 1975. – Vol. 7, № 1. – P. 1–13. 3. Bellman, R. E. Decision-Making in Fuzzy Environment / R. E. Bellman, L. A. Zadeh // Management Science. – 1970. – № 4. – P. 141–160. 4. Yuan, Y. Induction of fuzzy decision trees / Y. Yuan, M. Shaw // Fuzzy Sets and Systems. – 1995. – № 69. – P. 125–139. 5. Dorigo, M. Optimization, Learning and Natural Algorithms / M. Dorigo. – Milano: Politecnico di Milano, 1992. – 140 p. 6. Субботін, С. О. Ітеративні, еволюційні та мультиагентні методи синтезу нечіткологічних і нейромережних моделей: монографія [текст] / С. О. Субботін, А. О. Олійник, О. О. Олійник; під заг. ред. С. О. Субботіна. – Запоріжжя: ЗНТУ, 2009. – 375 с. 7. Dorigo, M. The Ant System: Optimization by a colony of cooperating agents / M. Dorigo, V. Maniezzo, A. Colomi // IEEE Transactions on Systems, Man, and Cybernetics. – 1996. – Part B, № 26 (1). – P. 29–41. 8. Олейник, Ал. А. Сравнительный анализ методов оптимизации на основе метода муравьиных колоний [текст] / Ал. А. Олейник // Комп'ютерне моделювання та інтелектуальні системи: Зб. наук. праць / За ред. Д. М. Пізи, С. О. Субботіна. – Запоріжжя: ЗНТУ, 2007. – С. 147–159. 9. Passino, K. M. Modeling and analysis of nest-site selection by honey bee swarms: The speed and accuracy trade-off / K. M. Passino, T. D. Seeley // Behavioral Ecology and Sociobiology. – 2006. – № 59. – P. 427–442. 10. Nakrani, S. On Honey Bees and dynamic allocation in an internet server colony / S. Nakrani, C. Tovey // Adaptive Behavior. – 2004. – № 12. – P. 223–240. 11. Subbotin, S. A. PSO with Control of Velocity Change for Feature Selection / S. A. Subbotin, Al. A. Oleynik // Induc-

tive Modeling : Proceedings of 2nd International Conference ICIM'2008, 15–19 May 2008. – Kyiv, 2008. – P. 81–83.
12. *De Castro, L. N.* Artificial Immune Systems. Part I. Basic Theory And Applications / L. N. De Castro, F. J. Von Zuben. – Technical Report No. Rt Dca 01/99. – Brazil : Feec/Unicamp, 1999. – 95 p.
13. *Олейник, А. А.* Метод оптимизации на основе моделирования перемещения бактерий с применением эволюционных операторов [текст] / А. А. Олейник, С. А. Субботин // Бионика интеллекта: науч.-техн. журнал. – 2008. – № 2 (69). – С. 137–144.

Поступила в редколлегию 30.10.2009

УДК 004.93

Гібридний мультиагентний підхід для побудови нейро-фаззі моделей у задачах діагностики / О.О. Олійник, С.О. Субботін // Біоніка інтелекту: наук.-техн. журнал. – 2009. – № 2 (71). – С. 85-92.

У статті досліджується мультиагентний підхід для моделювання складних об'єктів та систем. Розроблено гібридний мультиагентний метод структурно-параметричного синтезу нейро-фаззі мереж. Вирішено практичну задачу моделювання основних параметрів авіадвигунів.

Табл. 3. Бібліогр.: 13 найм.

UDC 004.93

Neuro-fuzzy model synthesis based on hybrid multiagent approach for diagnostic problem solving / A.A. Oleynik, S.A. Subbotin // Bionics of Intelligence: Sci. Mag. – 2009. – № 2 (71). – P. 85-92.

Hybrid multiagent approach for complex objects and systems modeling is investigated in the paper. Hybrid multiagent method of structural-parametrical synthesis of neuro-fuzzy nets is developed. The real-world problem of air-engine parameters modeling is solved.

Tab. 3. Ref.: 13 items.