

УДК 519.711

НЕЙРОНЕЧЕТКИЕ СИСТЕМЫ УПРАВЛЕНИЯ

М. В. Бураков,

канд. техн. наук, доцент

А. С. Коновалов,

д-р техн. наук, профессор

Санкт-Петербургский государственный университет
аэрокосмического приборостроения (СПбГУАП)

Рассматриваются механизмы нейронечеткой технологии разработки интеллектуальных систем управления сложными объектами. Этот комплексный подход предполагает использование имитационного моделирования для извлечения знаний о процессе управления, нечетких технологий для представления и накопления знаний, нейросетевых механизмов для реализации закона управления, а также генетического алгоритма для настройки регулятора.

Введение

Нейронечеткие регуляторы (ННР) используют нечеткие правила и нейронный механизм реализации этих правил. Основное достоинство такого подхода заключается в том, что функционирование нейронной сети (НС) получает семантическую интерпретацию, а нечеткие правила реализуются в виде, допускающем обучение и параллельную обработку. Исследования ННР ведутся с середины 80-х годов прошлого века ([1–4] и др.).

ННР могут использоваться практически в тех же областях, что и «обычные» нечеткие регуляторы и НС, а именно — в системах распознавания, прогнозирования, диагностики и управления [5, 6]. Однако процесс конструирования ННР отличается тем, что он ориентирован на извлечение неизвестных знаний из данных (*data mining*), что необходимо для реализации фазы структурного обучения регулятора, предшествующей фазе параметрического обучения. Эта важная особенность может сделать ННР эффективным инструментом при работе с имитационными моделями (ИМ) сложных объектов.

Проблема конструирования регуляторов для сложных объектов с помощью ИМ рассмотрена в работах [7, 8]. Основная задача здесь заключается в переходе от ИМ к модели управления объектом путем выделения конечного набора управляющих правил из большого массива экспериментальной ин-

формации. Повсеместное использование компьютерного моделирования позволяет утверждать, что применение ННР на этом направлении является одним из важнейших и весьма перспективных.

Нечеткие контроллеры и моделирование

Нечеткие регуляторы, или нечеткие логические контроллеры (НЛК), являются наиболее ярким приложением теории нечетких множеств Л. Заде [9]. Базовое понятие этой теории предполагает, что любой элемент множества $x \subset X$ может соответствовать сразу нескольким нечетким подмножествам A, B, \dots, Z с разной степенью принадлежности $\mu_A(x), \mu_B(x), \dots, \mu_Z(x)$, принимающей значения в диапазоне $[0, 1]$. Это позволяет описывать качественные понятия, вводя в рассмотрение лингвистические переменные (ЛП).

В НЛК используются обычно ЛП «ошибка управления» (ε^*), «производная ошибки управления» ($((d\varepsilon(t)/dt)^*)$) и «сигнал управления» (u^*). Эти ЛП принимают значения на множестве термов: «отрицательное большое» (ОБ), «положительное малое» (ПМ), «нулевое» (Н) и т. п. Каждый из термов является нечетким множеством. Механизмы работы НЛК детально описаны в обширной литературе (например, [10]). Здесь лишь подчеркнем, что нечеткие правила связывают наблюдаемую ситуацию и управление, которое должно в этой ситуации использоваться:

правило 1: если ($\varepsilon^* = \text{«Н»}$) и ($((d\varepsilon(t)/dt)^*) = \text{«ОМ»}$) то ($u^* = \text{«ПМ»}$);

правило 2: если ($\varepsilon^* = \text{«ОБ»}$) и ($((d\varepsilon(t)/dt)^*) = \text{«ПМ»}$) то ($u^* = \text{«Н»}$);

.....

.....

.....

правило N : если ($\varepsilon^* = \text{«ПМ»}$) и ($((d\varepsilon(t)/dt)^*) = \text{«ПС»}$) то ($u^* = \text{«ОМ»}$).

Обычно правила НЛК формулируются с помощью человека-эксперта. Но этого часто бывает недостаточно для заполнения всей базы знаний. Здесь кроется главная трудность использования НЛК. Другая проблема заключается в отсутствии математического доказательства устойчивости НЛК. Эти проблемы могут ограничивать использование НЛК в некоторых областях и приложениях. Но, с другой стороны, условия устойчивости обычно доказываются для упрощенной (линейной) модели системы. Убедиться в устойчивости системы управления сложным объектом можно либо после проведения натурных экспериментов, либо после серии вычислительных экспериментов с использованием адекватной (нелинейной) математической модели объекта.

НЛК присущи такие признанные достоинства, как малая чувствительность к внешним и параметрическим возмущениям в силу естественной адаптивности нечетких правил «в малом» и гибкость в силу того, что закон управления формируется из отдельных правил, так что каждое новое правило может дополнить описание закона управления в новой ситуации. Эти особенности открывают возможность использования компьютерного моделирования для формулирования правил управления объектом.

Несмотря на впечатляющую мощь современной вычислительной техники, использование ИМ для синтеза управления в реальном времени во многих случаях невозможно по ряду причин.

- Управляющее решение синтезируется после выполнения множества прогонов модели с варьируемыми параметрами. При этом нельзя гарантировать не только оптимальность полученного результата, но и саму возможность его получения за отведенное для принятия решения время.

- Для обеспечения адекватности модели объекту нужно решать проблему идентификации в реальном времени. В общем случае настройка модели также требует выполнения прогонов с изменяемыми параметрами.

Таким образом, можно констатировать, что обычно ИМ может лишь качественно соответствовать сложному объекту и не может использоваться в реальном времени. Однако при соблюдении качественного соответствия ИМ может использоваться в режиме *off line* для обучения интеллектуального регулятора. Аппаратом для обработки качественной информации служит теория нечетких множеств.

Методика формулирования нечетких правил по результатам компьютерного моделирования предполагает два этапа работы [3, 4].

На первом этапе многократно ставится задача управления при различных условиях. С помощью поисковых процедур синтезируется множество эталонных траекторий. Фиксируя вход и выход модели при движении по эталонной траектории в разные моменты времени, можно получить множество обучающих пар $\langle X, Y \rangle$, где X — вектор входа модели (управление), Y — вектор выхода модели.

На втором этапе обучающие пары обрабатываются с целью формирования нечетких правил управления. Для этого нужно преобразовать обучающие пары в нечеткую форму. Здесь возможны два варианта:

1. Заранее описываются ЛП таким образом, что их термы равномерно распределяются по соответствующим базовым шкалам входных и выходных переменных.

2. Каждое «четкое» значение входа и выхода модели преобразуется в нечеткую форму, становясь центральной точкой функции принадлежности терма ЛП, в которой $\mu_A(x) = 1$.

Соответственно, можно предложить два алгоритма построения нечетких правил, один из которых основан на обработке значений принадлежности элементов обучающих пар к термам ЛП, а второй — на векторной классификации с помощью вспомогательной сети Кохонена.

Полученный итоговый набор нечетких правил является предварительным, с его помощью решается задача оценки структуры НС прямого распространения, параметры которой подстраиваются на следующем этапе работы.

Выбор структуры нейронечеткой системы

Формирование нечетких правил управления. В работах [7, 11] была сформулирована простая методика для генерации нечетких правил из вход—выходных данных, получаемых при моделировании в режиме *off line*. Похожая методика независимо предложена в работе [12].

Рассмотрим для простоты изложения систему с двумя входами x_1 и x_2 и одним выходом y . Пусть имеется множество обучающих данных, полученных при движении объекта по эталонным траекториям:

$$(x_1^1, x_2^1, y^1), (x_1^2, x_2^2, y^2), \dots, (x_1^n, x_2^n, y^n).$$

Для получения нечетких правил выполняются следующие шаги.

Шаг 1. Входное и выходное пространства разделяются на нечеткие области — термы ЛП. Число термов каждой входной и выходной ЛП фиксировано, и они равномерно распределены в области определения каждой ЛП.

Для функций принадлежности термов вводится условие полноты ε [13] при $\varepsilon = 0,5$ или $\varepsilon = 1$ (рис. 1). Это условие означает, что для заданного значения x всегда существует терм T_i , такой что $\mu_{T_i}(x) \geq \varepsilon$. За счет этого условия нечеткая система выводов обеспечивает плавный переход от одного лингвистического значения к другому.

Шаг 2. Генерируются нечеткие правила. Сначала определяется степень принадлежности входных данных к отдельным термам ЛП. Например, пусть

$$\begin{aligned}\mu_{PM}(x_1^1) &= 0,8; \\ \mu_{PC}(x_2^1) &= 0,2; \\ \mu_H(y^1) &= 0,6,\end{aligned}$$

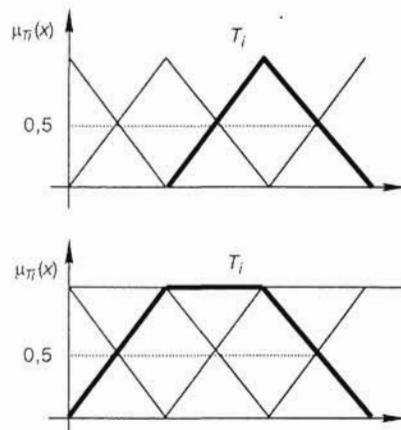
где $\mu_{PM}(x_1^1)$ — степень принадлежности входного значения x_1 к терму с названием «ПМ» соответствующей ЛП.

Таким образом, получается совокупность троек вида:

$$(0,8; 0,2; 0,6), (0,7; 0,5; 0,1) \dots$$

Эта совокупность троек степеней принадлежности описывает все возможные варианты правил для каждой тройки входных данных.

Затем выбирается тройка с максимальным значением принадлежности по двум входным и



■ Рис. 1. Описание термов лингвистических переменных

одной выходной переменной, которая порождает правило. Например, правило с номером 1:

$$(x_1^1, x_2^1, y^1) \Rightarrow (\mu_{\text{ПМ}}(x_1) = 0.8; \mu_{\text{ОС}}(x_2) = 0.6; \mu_{\text{ОБ}}(y) = 0.9) \Rightarrow$$

Правило 1: если $x_1 = \text{ПМ}$ и $x_2 = \text{ОС}$, то $y = \text{ОБ}$.

Шаг 3. Присвоение коэффициента определенности (КО) каждому правилу. Это позволяет выполнить сжатие базы правил, т. е. решить следующие задачи.

- во-первых, разрешить конфликты, когда одни и те же посылки в разных правилах порождают разные заключения;
- во-вторых, сократить общее число правил, так как учитываться могут только правила с максимальным КО.

Каждое правило активизируется с учетом своего КО, для вычисления которого можно использовать одну из двух формул (при приведенных выше данных):

$$\text{КО} = \mu_{\text{ПМ}}(x_1) \cdot \mu_{\text{ОС}}(x_2) \cdot \mu_{\text{ОБ}}(y) = 0.8 \cdot 0.6 \cdot 0.9 = 0.432;$$

$$\text{КО} = \min(\mu_{\text{ПМ}}(x_1) \cdot \mu_{\text{ОС}}(x_2) \cdot \mu_{\text{ОБ}}(y)) = \min(0.8 \cdot 0.6 \cdot 0.9) = 0.6.$$

Таким образом, если два или больше правил имеют одинаковые посылки и заключение, то используется правило, у которого больше КО.

Очевидно, этот метод может быть распространен и на системы со многими входами и многими выходами.

Использование сетей Кохонена. Для выделения нечетких правил из данных также можно использовать сети Кохонена — эффективный инструмент векторной классификации [4].

Будем считать, что U , V и W — нечеткие подмножества конечных множеств X , Y и Z мощностью соответственно n_x , n_y и n_z . Пусть имеется q наборов данных моделирования, описываемых тройками $(A_i^*, B_i^*$ и $C_i^*)$, принимающими значения на U , V и W .

Сеть Кохонена [14] имеет входной и выходной слой (рис. 2). Входной слой должен содержать $n_x + n_y + n_z$ входов, они соответствуют каждому элементу множеств X , Y и Z . Выходной слой должен содержать $n < q$ нейронов (точное число нейронов определяется по окончании обучения).

Каждый вход соединен со всеми выходами. Начальные значения весов присваиваются случайно. Введем обозначения: a_{ij} , b_{ij} , e_{ij} — значение веса между входом x_j , y_j , z_j соответственно и выходом i ; A_i , B_i , E_i — векторы, составленные из a_{ij} , b_{ij} , e_{ij} .

Пусть имеются входные наблюдения (A^* , B^* и C^*). Для каждого выходного нейрона необходимо вычислить три значения сходства:

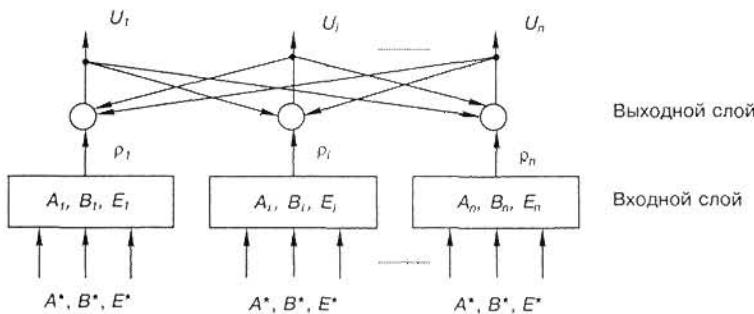
$$1) \rho_i^a = S((A^*(x_1), a_{i1}), (A^*(x_2), a_{i2}), \dots, (A^*(x_{n_x}), a_{in_x}));$$

$$2) \rho_i^b = S((B^*(y_1), b_{i1}), (B^*(y_2), b_{i2}), \dots, (B^*(y_{n_y}), b_{in_y}));$$

$$3) \rho_i^e = S((E^*(z_1), e_{i1}), (E^*(z_2), e_{i2}), \dots, (E^*(z_{n_z}), e_{in_z})).$$

Возможная формула для измерения сходства:

$$S((\alpha_1, \beta_1), (\alpha_2, \beta_2), \dots, (\alpha_n, \beta_n)) = 1 - \frac{1}{n} \sum_{i=1}^n |\alpha_i - \beta_i|.$$



■ Рис. 2. Сеть Кохонена в режиме кластеризации

На следующем шаге для вычисления окончательного выходного сигнала нейрона вводится переменная:

$$\rho_i = \min [\rho_i^a, \rho_i^b, \rho_i^e].$$

В выходном слое действует механизм латерального возбуждения-торможения (см. рис. 2). В результате соревнования происходит возбуждение или не возбуждение отдельных нейронов. Если нейрон i побеждает в соревновании и возбуждается, то он (и его ближайшие соседи) модифицируется в направлении входного вектора к (A^*, B^*, C^*) . Изменение весов нейрона i выполняется по формулам:

$$A'_i = A_i + \alpha(A^* - A_i);$$

$$B'_i = B_i + \alpha(B^* - B_i);$$

$$E'_i = E_i + \alpha(E^* - E_i).$$

Нейроны, близкие к i , также подстраиваются, но в меньшей степени. Так веса победивших нейронов приближаются к входным значениям.

Как показано в [14], в результате повторения этого процесса со всеми обучающими данными обеспечивается их кластеризация весами нейронов A_i , B_i и E_i в соответствии с обучающими данными. Один кластер относится к потенциальному правилу, которое можно вставить в базу правил. Каждый кластер представляется тройкой (A, B, E) , которая формирует основу правила:

если (W есть A) и (U есть B) то (U есть E)

Веса связей описывают функции принадлежности термов ЛП, относящиеся к посылкам и заключениям продукционных правил. Таким образом, можно считать, что здесь все правила имеют КО = 1.

Архитектура нейронечеткого регулятора

Архитектура HyFIS (Hybrid neural Fuzzy Inference System) представляет собой многослойную сеть прямого распространения [15]. Топология HyFIS показана на рис. 3.

Нейроны входного слоя получают входные состояния, а нейроны выходного слоярабатывают управляющие решения. Промежуточные слои описывают функции принадлежности и правила, что позволяет получить яс-

ное представление о механизме работы такой сети.

Нейроны слоя 1 просто передают входные («четкие») сигналы в последующий слой. Каждый нейрон слоя 1 связан только с теми нейронами слоя 2, которые описывают соответствующие термы ЛП.

Нейроны слоя 2 описывают термы входных ЛП. Для входного значения вычисляются функции принадлежности к термам соответствующей ЛП. Изначально веса связей между 1-м и 2-м слоем единичные, и функции принадлежности распределены равномерно в пространстве весов. Если существуют какие-то экспертные знания, то их можно использовать при инициализации.

Нейроны слоя 2 используют гауссовые функции принадлежности, два параметра которых — центр (c) и ширина (σ) — настраиваются при обучении:

$$y_j^2 = \mu_{T_j}(x_i) = e^{-\frac{(x_i - c_j)^2}{\sigma^2}}$$

На рис. 3 ЛП описываются с помощью термов «большой» (Б), «средний» (С), «маленький» (М). Во многих случаях нужно учитывать знак входной переменной, тогда используются термы «положительный большой» (ПБ), «отрицательный большой» (ОС) и т. д.

Выходом нейронов второго слоя являются функции принадлежности входного значения к термам ЛП.

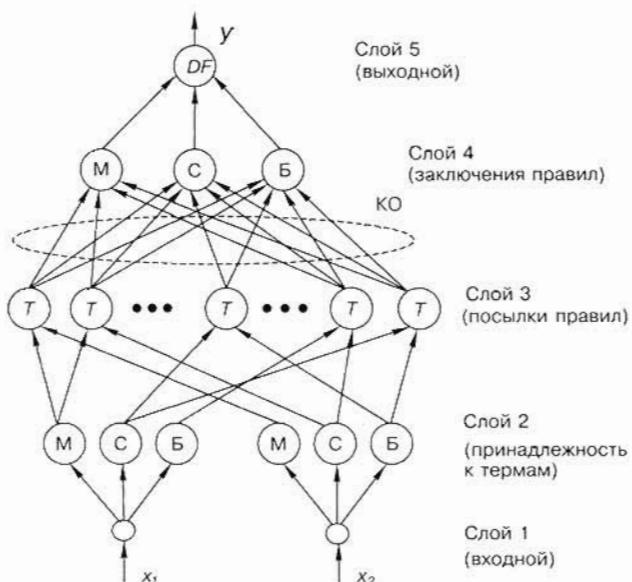
Каждый нейрон слоя 3 описывает посылки нечетких правил. Веса связей полагаются единичными. Нейрон этого слоя выполняет операцию *AND* (или вычисляет другую *T*-норму). Совокупность нейронов этого слоя формирует нечеткую базу правил. Функционирование каждого нейрона слоя 3 можно описать так:

$$y_j^3 = \min_{i \in I_j} (y_i^2),$$

где I_j — множество нейронов слоя 2, связанных с j -м нейроном слоя 3, y_i^2 — выход нейрона i слоя 2.

Веса связей между слоями 3 и 4 описывают КО правила.

Нейроны слоя 4 описывают возможные заключения правил. Каждый нейрон реализует функцию *OR*, учитывая совместное действие правил с одним и тем же термом заключения. Так описывается область восприятия выходной переменной. Уровень активизации нейрона слоя 4 описывает степень



■ Рис. 3. Нейронная сеть HyFIS

соответствия его функции принадлежности всем нечетким правилам вместе. Функционирование нейрона слоя 4 можно описать так:

$$y_k^4 = \max_{j \in I_k} (y_j^3 w_{kj}),$$

где I_k — множество нейронов слоя 3, связанных с k -м нейроном слоя 4, y_k^4 — выход нейрона k слоя 4.

Связи w_{kj} между слоями 3 и 4 действуют как механизм вывода, позволяющий избежать состязания правил. Каждое правило активизируется с некоторой степенью, представленной квадратом веса связи.

Слой 5. Здесь вырабатывается выходная (выходные) переменные системы, т. е. выполняется операция дефазификации (*DF*) — вычисления точного выходного значения. Для этого может применяться метод центра тяжести или центра области (ЦО). Схема дефазификации ЦО предполагает расчет выходного сигнала по формуле:

$$y_1^5 = \frac{\sum_{k \in I_1} y_k^4 \sigma_{ik} c_{ik}}{\sum_{k \in I_1} y_k^4 \sigma_k},$$

где I_1 — множество нейронов слоя 4, связанных с k -м нейроном слоя 5; σ_{ik} и c_{ik} — ширина и центральная точка функции принадлежности k -го нейрона слоя 4.

Веса связей нейронов слоев 4 и 5 единичные. Обучаются только веса между слоями 3 и 4.

Таким образом, архитектуру *HyFIS* выгодно использовать при процедуре выделения нечетких правил.

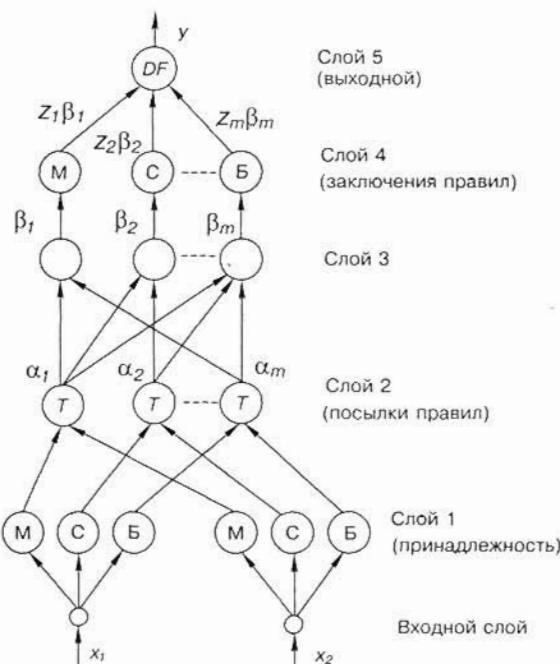
Архитектура ANFIS (*Adaptive Neuro-Fuzzy Inference System*) описана в работе [16]. Структура *ANFIS* представлена на рис. 4.

Функционирование *ANFIS* несколько отличается от *HyFIS*. Рассмотрим работу *ANFIS* подробнее.

- Нейроны входного слоя и слоя 1 работают аналогично *HyFIS*.
- Слой 2 реализует нечеткую *T*-норму, на его выходе появляется величина α_i , являющаяся результатом применения нечеткой операции *AND* по отношению к посылкам соответствующего правила.

- Нейроны слоя 3 вычисляют значения:

$$\beta_i = \frac{\alpha_i}{\alpha_1 + \alpha_2 + \dots + \alpha_m}.$$



■ Рис. 4. Структура сети ANFIS

- В слое 4 выполняется операция вычисления величины:

$$\beta_i z_i = \beta_i F_i^{-1}(\alpha_i),$$

где F – функция принадлежности, описывающая терм управления Z_i .

- Слой 5 выполняет операцию дефазификации:

$$z_0 = \beta_1 z_1 + \beta_2 z_2 + \dots + \beta_m z_m.$$

Настройка сети ANFIS также предполагает корректировку функций принадлежности заключений нечетких правил F_i . Очевидно, что эту структуру выгодно использовать при процедуре выделения нечетких правил на основании имитационного моделирования.

Параметрическая настройка регулятора

В процессе параметрической настройки регулятора требуется минимизировать ошибку управления по всем обучающим парам, а также проверить работу регулятора в тех ситуациях, которые не входили в обучающую выборку. При работе с нелинейными ИМ для этого необходимо использовать генетический алгоритм (ГА). ГА основан на фундаментальных представлениях о механизме эволюции как процессе выживания наиболее приспособленных особей и гибели наименее приспособленных [17].

При использовании ГА настраиваемые параметры регулятора (КО правил или параметры функций принадлежности) кодируются двоичными цепочками конечной длины — хромосомами. Совокупность хромосом образует популяцию — множество точек многомерного пространства, в котором происходит поиск решения. Каждая хромосома оцени-

вается путем моделирования переходного процесса (рис. 5).

При управлении динамическим процессом общая ошибка регулирования $\varepsilon(t)$ должна подсчитываться на достаточно большом количестве точек переходного процесса (N), тогда пригодность хромосомы можно оценить по формуле:

$$P = \frac{1}{1 + \sum_{i=1}^N \varepsilon(t_i)}.$$

На основании этих оценок «хорошие» хромосомы популяции размножаются с помощью генетического оператора копирования. Остальные генетические операторы — скрещивания и мутации — позволяют исследовать все пространство поиска решения [18, 19].

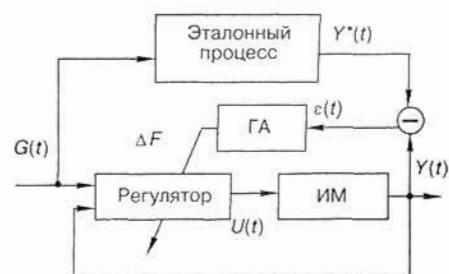
Успех параметрической настройки зависит от того, насколько верно была выбрана структура регулятора. В сложных случаях процесс обучения может включать несколько шагов, с чередованием структурной и параметрической настройки регулятора.

Практические приложения

Описанная методика может быть весьма эффективна в задачах управления сложными динамическими объектами. Рассмотрим два примера.

1. Задача управления подводным исследовательским буксируемым комплексом (БК) [20, 21]. БК представляет собой систему судно—трос—подводный аппарат (ПА). Траектория движения ПА определяющим образом зависит от динамики судна и троса длиной несколько километров. Нелинейная ИМ БК позволяет получить лишь относительно малое количество прогнозов в ускоренном времени. Но в режиме *off line* может быть накоплено большое количество данных моделирования. В результате структурирования этой информации выделяется ограниченное число нечетких управляющих правил, параметры которых корректируются с учетом оперативной информации [20, 21].

2. Задача управления посадкой самолета вертикального взлета и посадки [22]. Используя нелинейную ИМ объекта управления, можно с помощью поисковых процедур синтезировать в режиме *off line* большое количество удовлетворительных траекторий движения объекта. После выполнения кластеризации пространства входов и выходов получается ограниченный набор нечетких правил,



■ Рис. 5. Настройка регулятора с помощью ГА

задающий структуру управляющей НС, параметры которой потом подвергаются коррекции. Для обеспечения адаптации в реальном времени возможно взаимодействие конкурирующих структур [22].

Заключение

И система нечетких правил, и искусственная НС являются универсальными аппроксиматорами — с их помощью можно описать любую нелинейную функцию. Однако только соединение этих двух подходов в рамках ННР позволяет одновременно использовать способности НС к обучению и удобства представления и анализа нечетких производственных правил. Конструирование ННР включает два этапа, на каждом из которых необходимо использование ИМ объекта.

На первом этапе происходит структурный синтез регулятора — определение количества продук-

ционных правил, достаточного для описания закона управления. Как было показано в статье, здесь возможны два подхода: либо предварительное описание термов ЛП, либо поиск этого описания в результате кластеризации. Соответственно, при первом варианте выгодно использовать архитектуру *HyFIS*, а при втором варианте — архитектуру *ANFIS*.

На втором этапе происходит параметрическая (точная) настройка — уточнение тех или иных параметров НС, реализующей нечеткую производственную систему. Для архитектуры *HyFIS* — это коэффициенты определенности правил, а для архитектуры *ANFIS* — параметры функций принадлежности. Здесь выгодно использовать ГА — мощный инструмент поиска глобального экстремума целевой функции.

Описанная методика может использоваться при разработке систем управления многими реальными сложными объектами.

Литература

1. Gupta M. M., Rao D. H. On the principles of fuzzy neural networks // Fuzzy Sets and Systems. — 1984. — Vol. 61. — P. 1–18.
2. Kosko B. Neural network and fuzzy systems. Englewood Cliffs, NJ: Prentice-Hall, 1991.
3. Keller J. M., Yager R. R., & Tahani H. Neural network implementation of fuzzy logic // Fuzzy sets and systems. — 1992. — № 45. — P. 1–12.
4. Ronald R. Yager. Modeling and Formulating Fuzzy Knowledge Bases Using Neural Networks // Neural Networks. — 1994. — Vol. 7. — № 8. — P. 1273–1283.
5. Ayoubi M., Isermann R. Neuro-fuzzy systems for diagnosis // Fuzzy sets and systems. — 1997. — № 89. — P. 289–307.
6. Jang J. S. R., Sun C. T., Mizutani E. Neuro-Fuzzy and Soft Computing. A Computational Approach to Learning and Machine Intelligence. Prentice-Hall International, 1997. — 613 p.
7. Бураков М. В., Попов О. С. Совместное использование имитационного моделирования и экспертных процедур для управления динамическими объектами // «Известия ВУЗов. Приборостроение». — 1994. — № 5–6. — С. 11–13.
8. Бураков М. В., Коновалов А. С., Попов О. С. Адаптивное управление сложными объектами // Оборонная техника. — 1998. — № 6–7. — С. 56–61.
9. Mamdani E. H. Application of fuzzy algorithms for control of simple dinamic plant. — IEEE Proc., 1974. — V. 121. — № 12. — P. 1585–1588.
10. Бураков М. В., Попов О. С. Интеллектуальные системы управления. Учебное пособие. — СПб.: ГААП, 1997. — 108 с.
11. Бураков М. В., Попов О. С. Формирование базы знаний управляющей экспертной системы. Рук. деп. в ВИНИТИ 19.05.93. — № 1329-В93. — 21 с.
12. Wang I. X., Mendel J. M. Generating fuzzy rules by learning from examples. IEEE Transactions on System, Man and Cybernetics — 1992. — 22(6). — P. 1414–1427
13. Lee C. C. Fuzzy logic in control systems: fuzzy logic controller — part 1 and 2. IEEE Transaction on System, Man and Cybernetics. — 1990. — 20(2). — P. 404–435.
14. Kohonen T. Self-organization and associative memory. Berlin, Springer-Verlag, 1984.
15. Kim J., Kasabov N. HyFIS: adaptive neuro-fuzzy inference systems and their application to nonlinear dynamical systems // Neural networks, 12(1999). — P. 1301–1319.
16. Jang J. S. R. ANFIS: Adaptive network based fuzzy inference systems. IEEE Trans. on Systems, Man, and Cybernetics. 23(03): 665–685. May 1993.
17. Goldberg D. E. Genetic Algorithms in Search, Optimization and Machine Learning. Addison-Wesley, Reading, MA. 1989.
18. Бураков М. В. Синтез нейронного регулятора // Изв. Академии наук. Теория и системы управления. — 1999. — № 3. — С. 140–145.
19. Burakov M. V., Konovalov A. S. Peculiarities of Genetic Algorithm Usage when Synthesizing Neural and Fuzzy Regulators // Advanced Computer Systems. Editors J. Soldek, J. Pejas. The Kluwer International Series in Engineering and Computer Science. P.139–148. KLUWER ACADEMIC PUBLISHERS, Boston/ Dordrecht/ London, 2002.
20. Burakov M. V. Synthesis Of The Fuzzy Controller // Proceeding of the first Inter. Conf. on Computer's Methods in Control Systems «CMCS' 97 », Szczecin, Poland, December 11–12, 1997. — P. 77–82.
21. Popov O. S., Burakov M. V. Principles of Construction and Structure of an Automated Control System by an Underwater Towed Complex for Ocean Researchers // Proc. of the Second Int. Conf. on Marine Technology «ODRA 97», Szczecin, Poland, 13–15 may 1997. — P. 465–472.
22. Burakov M., Konovalov A. Development of dynamic object's neural controller by means of decomposition // Int. Conf. Of Advanced Computer systems «ACS'2000», 23–25 October 2000, Szczecin, Poland. — P.307–311.